



# Méthodes d'analyse de texture pour la cartographie d'occupations du sol par télédétection très haute résolution : application à la forêt, la vigne et les parcs ostréicoles

Olivier Regniers

## ► To cite this version:

Olivier Regniers. Méthodes d'analyse de texture pour la cartographie d'occupations du sol par télédétection très haute résolution : application à la forêt, la vigne et les parcs ostréicoles. Traitement du signal et de l'image [eess.SP]. Université de Bordeaux, 2014. Français. NNT : 2014BORD0284 . tel-01152599

**HAL Id: tel-01152599**

**<https://theses.hal.science/tel-01152599>**

Submitted on 18 May 2015

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

# THÈSE

PRÉSENTÉE  
POUR OBTENIR LE GRADE DE

## DOCTEUR DE L'UNIVERSITÉ DE BORDEAUX

Ecole Doctorale des Sciences Physiques de l'Ingénieur  
Spécialité : Automatique, Productique, Signal et Image, Ingénierie Cognitive

par

**OLIVIER REGNIERS**

Méthodes d'analyse de texture pour la cartographie d'occupations du  
sol par télédétection très haute résolution

—

Application à la forêt, la vigne et les parcs ostréicoles

Soutenue le 11 décembre 2014 devant le jury composé de :

JOCELYN CHANUSSOT	Professeur des Universités, GIPSA-LAB	Président
GILLES RABATEL	Directeur de Recherche, IRSTEA Montpellier	Rapporteur
GREGOIRE MERCIER	Professeur des Universités, Télécom Bretagne	Rapporteur
JULIO MARTIN HERRERO	Professeur des Universités, Université de Vigo	Examineur
CHRISTIAN GERMAIN	Professeur des Universités, Bordeaux Sciences Agro	Directeur de thèse
LIONEL BOMBRUN	Maître de Conférences, Bordeaux Sciences Agro	Co-directeur de thèse

Préparée à l'Université de Bordeaux  
Laboratoire d'accueil : Laboratoire IMS  
351, avenue de la Libération – 33405 Talence Cedex



# Remerciements

Mes premiers remerciements s'adressent à mes deux encadrants de thèse, Christian Germain et Lionel Bombrun, aux côtés desquels il a été plus qu'agréable de travailler au cours de ces trois années de thèse. Malgré le sujet de thèse a priori éloigné de mes compétences, ils m'ont accordé leur confiance et si ce pari est aujourd'hui réussi, c'est en majeure partie grâce à eux et à la disponibilité dont ils ont fait preuve tout au long de ce travail. Je ne peux passer sous silence le nombre incalculable de fois où j'ai passé ma tête par la porte de leur bureau pour les solliciter avec une question, une idée, une remarque. A chaque fois, ils ont répondu présents. Merci à toi, Christian, pour ton humour et pour l'opportunité que tu m'as offerte de découvrir les plaisirs de l'enseignement. Merci à toi, Lionel, pour ta patience et ton rire toujours aussi communicatif.

Je ne peux oublier dans ces remerciements tous ceux qui ont participé activement à mon comité de thèse et qui ont suivi de près mes travaux pendant ces trois années : Dominique Guyon et Jean-Pierre Wigneron de l'INRA de Bordeaux, Samia Boukir et Nesrine Chehata de l'ENSEGID, Virginie Lafon de Géo-Transfert, Jean-Pierre Da Costa et Gilbert Grenier de l'IMS. Chacune de ces réunions m'a permis de prendre un recul salutaire sur mon travail et de repartir avec le plein de nouvelles pistes et de suggestions constructives. Je tiens à remercier tout particulièrement Dominique Guyon, mon coach attitré en culture de pins maritimes, pour ses nombreux conseils toujours pertinents, ainsi que Virginie Lafon pour sa disponibilité et l'opportunité que j'aurai grâce à elle de retourner maintes fois sur le bassin déguster quelques huîtres.

Je souhaite également exprimer ma gratitude à Claire Tinel et Delphine Fontannaz du CNES pour nous avoir aidés à disposer d'images Pléiades de qualité et nous avoir soutenus dans la valorisation de nos résultats. Je remercie également Christelle Barbey et Jean-Charles Samalens de Telespazio pour les images qu'ils ont mises à notre disposition et pour l'intérêt qu'ils ont montré dans notre travail.

Un tout grand merci à tous mes collègues de l'équipe signal et image à l'IMS pour les nombreux bons moments que nous avons partagés au cours de ces trois années. Aux permanents et membres de l'équipe, Jean-Pierre, Jean-François, Audrey, Guillaume, Rémi, Marc, Salem, Pascal, Romain, Jacques, Barna et le maître des lieux Yannick. A tous les stagiaires, doctorants et post-doctorants que j'ai côtoyés pendant ces années. A mes voisins de bureau, Cornelia et sa propension toujours inexplicable à tester les lois de la gravité avec sa tasse de café encore chaud, Cédric et ses dessins mystiques de spaghettis entortillés, Julien et son cactus increvable, Guillaume Z. et sa capacité incroyable à tenir une conversation cohérente sur le championnat kazakh de football 1996 (division 2), Guillaume B. pour son appétit abyssal ainsi que son habilité à encaisser des flutchs sans lâcher de multiple noms d'oiseaux, Guillaume R. et ses dandinements frénétiques sans consommation assumée de produits illicites, « El Cartel » pour avoir rendu mes posters plus présentables et fait voyager ma souris dans des contrées inexplorées. Merci aussi à mes deux secrétaires préférées, Valérie et Céline, pour avoir égayé mes nombreuses pauses café de leur gentillesse et de leurs rires communicatifs. Je salue enfin tous ceux que j'ai rencontrés lors de mes missions d'enseignement à Bordeaux Sciences Agro. Un merci tout particulier à Nathalie pour m'avoir soutenu dans mes premiers pas en enseignement.

Enfin, je tiens à remercier tout particulièrement ma famille et mes amis du plat pays pour leur soutien inconditionnel et leurs nombreuses visites dans notre nouveau chez nous souvent accompagnés dans leurs bagages de quelques breuvages houblonnés pour nous rappeler qu'en Belgique, on ne fait pas les choses à moitié.





# Table des matières

<b>Introduction .....</b>	<b>1</b>
<b>Chapitre I - Méthodes d'analyse de texture appliquées en télédétection : Etat de l'art....</b>	<b>5</b>
<b>I.1 Introduction.....</b>	<b>6</b>
<b>I.2 Notion de texture.....</b>	<b>6</b>
<b>I.3 Méthodes d'analyse de la texture .....</b>	<b>7</b>
I.3.1 Représentation statistique des niveaux de gris.....	8
I.3.1.1 Matrice de co-occurrence des niveaux de gris .....	8
I.3.1.2 Variogrammes.....	14
I.3.2 Analyse fréquentielle de la texture .....	16
I.3.2.1 Transformée de Fourier .....	17
I.3.2.2 Filtres de Gabor.....	18
I.3.2.3 Transformée en ondelettes.....	19
I.3.3 Modélisation probabiliste des sous-bandes d'ondelettes .....	23
I.3.3.1 Distribution Gaussienne généralisée .....	23
I.3.3.2 Modèles multivariés.....	25
<b>I.4 Comparatif des méthodes d'analyse de texture .....</b>	<b>30</b>
I.4.1 Les matrices de co-occurrence comme méthode de référence.....	31
I.4.2 Représentation des sous-bandes d'ondelettes .....	31
<b>I.5 Conclusion .....</b>	<b>32</b>
<b>Chapitre II - Méthodologie.....</b>	<b>35</b>
<b>II.1 Introduction .....</b>	<b>36</b>
<b>II.2 Recherche d'images par leur contenu .....</b>	<b>36</b>
II.2.1 Principe général .....	36
II.2.2 Notion de similarité .....	37
II.2.2.1 Mesure de similarité appliquée aux matrices de co-occurrence.....	38
II.2.2.2 Mesure de similarité appliquée aux modèles multivariés .....	38
II.2.3 Evaluation des performances.....	40
II.2.3.1 Taux de reconnaissance moyen .....	41
II.2.3.2 Courbe de Rappel/Précision .....	41
<b>II.3 Classification supervisée .....</b>	<b>42</b>

II.3.1 Stratégies de classification.....	43
II.3.1.1 Avec vérité-terrain .....	43
II.3.1.2 Sans vérité-terrain.....	44
II.3.2 Algorithmes de classification .....	46
II.3.2.1 Méthode des $k$ plus proches voisins .....	46
II.3.2.2 Classification par maximum de vraisemblance.....	47
II.3.2.3 Machine à Vecteurs de Support.....	47
II.3.3 Evaluation des performances.....	49
<b>II.4 Conclusion .....</b>	<b>50</b>
<b>Chapitre III - Application à la différenciation de classes d'âge de forêt de pin maritime</b> .....	<b>51</b>
<b>III.1 Introduction.....</b>	<b>52</b>
<b>III.2 Site d'étude et données .....</b>	<b>53</b>
III.2.1 Le massif de la forêt des Landes de Gascogne.....	53
III.2.2 Site d'étude et données satellite .....	54
III.2.3 Bases de données de patches de texture .....	57
III.2.4 Données de référence de classes d'âge.....	59
<b>III.3 Indexation par CBIR .....</b>	<b>60</b>
III.3.1 Stratégie d'application des méthodes.....	60
III.3.1.1 Réglage des paramètres de la matrice de co-occurrence.....	60
III.3.1.2 Configuration de la transformée en ondelettes .....	62
III.3.2 Résultats d'indexation .....	63
<b>III.4 Résultats de classification.....</b>	<b>68</b>
III.4.1 Résultats obtenus par $k$ -NN.....	69
III.4.2 Résultats obtenus par SVM .....	74
<b>III.5 Conclusions et perspectives.....</b>	<b>76</b>
III.5.1 Conclusions .....	76
III.5.2 Perspectives.....	77
<b>Chapitre IV - Application à la détection des parcelles viticoles.....</b>	<b>79</b>
<b>IV.1 Introduction.....</b>	<b>80</b>
<b>IV.2 Site d'étude et données .....</b>	<b>81</b>
IV.2.1 Site d'étude et données satellite .....	81
IV.2.2 Sources d'altération de la texture.....	82
IV.2.3 Bases de données de patches de texture.....	84

<b>IV.3 Indexation par CBIR .....</b>	<b>85</b>
IV.3.1 Stratégie d'application des méthodes.....	85
IV.3.1.1 Paramétrisation des matrices de co-occurrence .....	85
IV.3.1.2 Configuration de la transformée en ondelettes .....	87
IV.3.2 Résultats d'indexation.....	87
<b>IV.4 Résultats de classification .....</b>	<b>91</b>
IV.4.1 Segmentation par filtres de Gabor .....	91
IV.4.2 Comparaison des résultats de classification et segmentation .....	93
<b>IV.5 Conclusions et perspectives .....</b>	<b>100</b>
IV.5.1 Conclusions.....	100
IV.5.2 Perspectives.....	101
<b>Chapitre V - Application à la détection de parcs ostréicoles.....</b>	<b>103</b>
<b>V.1 Introduction .....</b>	<b>104</b>
<b>V.2 Site d'étude et données .....</b>	<b>106</b>
V.2.1 Site d'étude et données satellite .....	106
V.2.2 Bases de données de patches de texture .....	107
V.2.3 Données de validation .....	109
<b>V.3 Indexation par CBIR.....</b>	<b>109</b>
V.3.1 Paramétrisation des matrices de co-occurrence.....	109
V.3.2 Résultats d'indexation .....	111
<b>V.4 Résultats de classification .....</b>	<b>114</b>
V.4.1 Résultats de classification .....	114
V.4.2 Résultats de validation .....	117
<b>V.5 Conclusions et perspectives.....</b>	<b>120</b>
V.5.1 Conclusions .....	120
V.5.2 Perspectives.....	120
<b>Conclusions .....</b>	<b>123</b>
<b>Perspectives.....</b>	<b>125</b>
<b>ANNEXES.....</b>	<b>127</b>
<b>Stratégies d'approximation de la distance géodésique pour les modèles MGG et SIRVg0 .....</b>	<b>129</b>
<b>Cartographie des pratiques culturelles d'enherbement en Entre-Deux-Mers.....</b>	<b>132</b>
<b>Bibliographie.....</b>	<b>137</b>

<b>Liste des publications de l’auteur .....</b>	<b>146</b>
<b>Résumé .....</b>	<b>149</b>
<b>Abstract .....</b>	<b>149</b>





# Liste des Abréviations

ACP	Analyse en Composantes Principales
ARR	Taux de Reconnaissance Moyen ( <i>Average Retrieval Rate</i> )
BIC	Critère d'Information Bayésienne ( <i>Bayesian Information Criterion</i> )
BPT	Binary Partition Tree
BRGM	Bureau de Recherches Géologiques et Minières
CBIR	Recherche d'Images par leur contenu ( <i>Content Based Image Retrieval</i> )
CNES	Centre National d'Etudes Spatiales
COL	Dépendance couleur
CRPFA	Centre Régional de la Propriété Forestière d'Aquitaine
db4	Filtre d'ondelettes Daubechies avec 4 moments nuls
DDTM	Direction Départementale des Territoires et de la Mer
DT-CWT	Transformée en Ondelettes Complexe par Arbre Dual ( <i>Dual Tree Complex Wavelet Transform</i> )
DWT	Transformée en Ondelettes Discrète ( <i>Discrete Wavelet Transform</i> )
FP	Estimateur du Point Fixe de la matrice de covariance ( <i>Fixed Point</i> )
GCG	Modèle Gamma sur Copule Gaussienne
GD	Distance Géodésique
GGD	Distribution Gaussienne Généralisée ( <i>Generalized Gaussian Distribution</i> )
GLCM	Matrice de Co-occurrence des Niveaux de Gris ( <i>Grey Level Co-Occurrence Matrix</i> )
GLCM_INV	Matrice de Co-occurrence en moyennant les descripteurs sur les 4 orientations
GSD	Distance d'échantillonnage au sol ( <i>Ground Sampling Distance</i> )
IFN	Inventaire Forestier National
INRA	Institut National de la Recherche Agronomique
JD	Divergence de Jeffrey
KLD	Divergence de Kullback-Leibler
k-NN	k plus proches voisins ( <i>k Nearest Neighbors</i> )
MGG	Gaussienne Généralisée Multivariée ( <i>Multivariate Generalized Gaussian</i> )
ML	Maximum de Vraisemblance ( <i>Maximum Likelihood</i> )
OA	Précision globale ( <i>Overall Accuracy</i> )
PA	Précision du Producteur ( <i>Producer's Accuracy</i> )
PAN	Panchromatique
PDF	Fonction de Densité de Probabilité ( <i>Probability Density Function</i> )



PIR	Proche Infrarouge
SAR	Radar à synthèse d'ouverture ( <i>Synthetic Aperture Radar</i> )
SCM	Modèle multivarié Gaussien avec estimateur SCM ( <i>Sample Covariance Matrix</i> ) de la matrice de covariance
SIRV	Vecteur Aléatoire Sphériquement Invariant ( <i>Spherically Invariant Random Vector</i> )
SIRVgauss	Modèle SIRV avec une distribution Gaussienne multivariée
SIRVg0	Modèle SIRV avec une distribution G0
SLIC	Simple Linear Iterative Clustering
SP	Dépendance spatiale
SPOT	Satellite Pour l'Observation de la Terre
SProt	Dépendance spatiale après rotation à $0^\circ$ des textures anisotropes
STELLA	Site Atelier de Télédétection Aquitain
SVM	Machine à Vecteurs de Support ( <i>Support Vector Machine</i> )
THR	Très Haute Résolution
UA	Précision de l'Utilisateur (User's Accuracy)
WCF	Descripteurs de Co-occurrence sur ondelettes ( <i>Wavelet Co-occurrence Features</i> )





# Introduction

Depuis 1999 et le lancement du premier satellite optique à Très Haute Résolution (THR) spatiale IKONOS, la disponibilité et l'accessibilité des images satellite optiques THR d'observation de la Terre se sont considérablement accrues. Les quinze dernières années ont ainsi vu le déploiement de près d'une dizaine de satellites de résolution métrique ou submétrique (QuickBird, GeoEYE, WorldView, Pléiades, ...) rivalisant en termes de résolutions spatiale, spectrale et temporelle. Le niveau de détail atteint dans ces images permet de discerner sur la surface terrestre des objets uniquement observables au travers de leurs propriétés spectrales dans les images de résolution spatiale plus grossière. Certains de ces objets sont caractérisés par des structures géométriques présentant une organisation spatiale régulière propre à certains types de couverts. Grâce à la très haute résolution de ces images satellite, ces objets sont donc caractérisables par l'analyse de leur organisation spatiale.

Dans les paysages façonnés par l'activité humaine, bon nombre d'occupations du sol déploient typiquement cette organisation spatiale structurée (Figure I.1). Dans les zones agricoles, ce sera le cas de certaines cultures céréalières, des vergers ou des parcelles viticoles qui affichent dans les images THR des structures régulières en rangs. Les forêts cultivées telles que les peuplements de pins maritimes dans la forêt des Landes de Gascogne ou les cultures de peupliers sont aussi marquées par un agencement spatial spécifique en raison des pratiques culturales et des plantations en rang. Dans les applications en zones côtières, certaines cultures conchylicoles comme par exemple les tables ostréicoles présentent également une organisation spatiale distinctive dans le paysage. Enfin, les zones urbaines par la répétition dans l'espace des bâtiments constituent aussi un canevas structuré dans les images THR.

Dans ce contexte, les méthodes de classification ou de segmentation ont dès lors tout intérêt à tirer profit d'une analyse orientée objet pour caractériser ces classes d'occupation du sol. Le développement de telles méthodes est donc naturellement devenu un enjeu majeur de la recherche en télédétection optique [[Blaschke, 2010](#)]. Les approches basées sur l'analyse de textures ont souvent été avancées comme une solution performante dans ce contexte. L'objectif principal de ces approches est de représenter statistiquement les dépendances spatiales locales en considérant un ensemble de




Figure I.1 : Exemples d'occupations du sol texturées dans les images optiques THR.

voisinages définis autour des pixels de l'image. Cette représentation statistique de la texture aboutit généralement à l'extraction d'un nombre restreint de paramètres, utilisables ensuite dans des algorithmes classiques de classification ou de segmentation. De nombreux outils ont ainsi été proposés pour réaliser cette représentation statistique, tels que les matrices de co-occurrence des niveaux de gris, les variogrammes ou la transformée de Fourier [Maillard, 2003].

Par ailleurs, des travaux menés ces dernières années en traitement d'images ont démontré que la décomposition en ondelettes permet de caractériser efficacement le contenu textural des images [Mallat, 1989]. En effet, plutôt que de chercher à représenter la texture directement dans le domaine de l'image, l'espace de la transformée en ondelettes permet d'analyser indépendamment chaque sous-bande issue de la décomposition dans un schéma de représentation multi-échelles et multi-orientations de la texture. Pour caractériser chacune des sous-bandes, certains auteurs ont ainsi investigué l'utilisation de modèles statistiques univariés pour modéliser l'histogramme empirique des coefficients d'ondelettes [Do & Vetterli, 2002]. Toutefois, cette approche n'exploite pas pleinement l'information texturale contenue dans les sous-bandes en ne considérant pas directement les dépendances spatiales locales. Pour enrichir la représentation statistique des sous-bandes, d'autres études plus récentes ont fait appel à des modèles multivariés pour caractériser la distribution de ces dépendances spatiales. Ces modèles sont par exemple la distribution Gaussienne généralisée multivariée [Verdoolaege *et al.*, 2008], les vecteurs aléatoires sphériquement invariants (SIRV) [Bombrun *et al.*, 2011a] et les modèles basés sur les copules [Kwitt & Uhl, 2009]. Les paramètres de lois de ces modèles (matrice de covariance, paramètres de forme, paramètres d'échelle, ...) constituent une signature texturale exploitable dans des algorithmes de classification et de segmentation.

Les performances de ces modèles multivariés appliqués sur les sous-bandes d'une décomposition en ondelettes ont principalement été évaluées jusqu'ici dans des contextes d'indexation d'images issues de base de données génériques de textures [Brodatz ; VisTex]. A notre connaissance, ces modèles ont fait l'objet de peu d'études visant à les appliquer à la caractérisation d'images de télédétection optique. L'objectif principal de ce travail de thèse est donc d'explorer les potentialités de ces modèles pour la classification d'images satellite à très haute résolution en se focalisant sur trois thématiques applicatives caractéristiques des enjeux de gestion du territoire rencontrés en région Aquitaine : la différenciation de classes d'âge de peuplements de pins maritimes, la détection de parcelles viticoles et la détection de cultures ostréicoles sur tables.

Les travaux présentés dans ce mémoire s'inscrivent dans le cadre plus large du projet STELLA THR cofinancé par le CNES et le conseil régional d'Aquitaine et impliquant plusieurs laboratoires aquitains de recherche en télédétection. Ce projet se focalise sur l'analyse spatio-temporelle d'images satellite à très haute résolution spatiale (images Pléiades principalement) pour la cartographie fine des changements de l'occupation des surfaces avec une visée multi-thématique (littoral, forestier et viticole). La thèse est quant à elle cofinancée par le conseil régional d'Aquitaine et Bordeaux Sciences Agro.

L'utilisation d'analyse texturale pour la classification d'images de télédétection THR a fait l'objet de nombreuses études ayant recours à des méthodes reposant sur des principes divers de représentation de la texture. Dans le **premier chapitre** de cette thèse, nous établissons un état de l'art des méthodes d'analyse texturale couramment employées en classification d'images THR. Le principe de ces méthodes est décrit et des exemples de leur utilisation sont présentés. L'approche de modélisation probabiliste des sous-bandes d'une décomposition en ondelettes est ensuite présentée en introduisant les principaux modèles multivariés utilisés dans la littérature dans un contexte d'indexation d'images.

L'ensemble des stratégies d'évaluation et de classification employées pour l'analyse des performances des modèles multivariés sur sous-bandes d'ondelettes sont ensuite présentés dans le **deuxième chapitre**. Afin de comparer les textures, une notion de similarité propre à chaque modèle multivarié est introduite. Avant de les appliquer dans un contexte de classification supervisée, les modèles sont comparés dans le cadre d'une procédure de recherche d'images par leur contenu textural (indexation). Le principe général de cette procédure est détaillé et les outils d'évaluation des performances sont présentés. La contribution principale dans ce chapitre concerne la stratégie de classification supervisée proposée. Celle-ci se base sur l'utilisation d'une base de données de patches de texture pour l'apprentissage et sur une pré-segmentation de l'image à classer. Enfin, les classifieurs employés lors de la classification sont également décrits dans ce chapitre.

Les trois chapitres suivants sont consacrés à l'évaluation des performances de classification des modèles multivariés dans les contextes applicatifs proposés dans cette étude. Le **troisième chapitre** se concentre ainsi sur la capacité des modèles multivariés à différencier des classes d'âge de peuplements mono-spécifiques de pins maritimes à partir d'images Pléiades et GeoEYE acquises sur la forêt des Landes de Gascogne. Les pratiques culturelles adoptées dans la gestion de ces peuplements sont en effet suffisamment stables pour considérer l'existence d'une corrélation entre l'âge des peuplements et la distribution spatiale des arbres. Chaque classe d'âge définie est donc caractérisée par un motif textural spécifique. Les contributions principales de ce chapitre résident dans les expérimentations présentées et dans l'intérêt démontré de l'utilisation des modèles multivariés et de la THR dans ce contexte applicatif particulier. Cette partie de notre étude a été menée en collaboration avec Dominique Guyon de l'UMR ISPA de l'INRA de Bordeaux ainsi que Jean-Charles Samalens de Telespazio EarthLab. Par ailleurs, une autre collaboration en cours menée avec Samia Boukir et Li Guo du laboratoire Géoressources et Environnement de l'INP de Bordeaux porte sur l'utilisation de paramètres de texture issus de modèles multivariés par la méthode des log-cumulants. Cette étude se place dans un contexte de détection de changements post-tempête à partir d'un classifieur basé sur la méthode des forêts aléatoires. Les résultats de ces travaux ne sont pas présentés dans ce mémoire.

Outre les forêts cultivées, d'autres types de couverts agricoles peuvent être détectés et caractérisés dans les images THR. Le **quatrième chapitre** est ainsi dédié à l'évaluation du potentiel des modèles multivariés à détecter efficacement les parcelles viticoles dans des images panchromatiques Pléiades. La difficulté majeure rencontrée dans cette thématique relève du rapport élevé entre résolution spatiale et distance entre les rangs de vignes résultant en une perception plus ou moins altérée des textures dans l'image. La sensibilité des modèles à cette perturbation est ainsi examinée. Les contributions principales de ce chapitre relèvent de cette analyse de sensibilité, de la comparaison avec d'autres approches d'analyse texturale (matrices de co-occurrence et filtres de Gabor) et de l'intérêt démontré de l'utilisation des modèles multivariés dans ce contexte applicatif.

Enfin, une troisième et dernière thématique est abordée dans le **cinquième chapitre**. Celui-ci se focalise sur la capacité des modèles multivariés à détecter les cultures ostréicoles sur tables dans le bassin d'Arcachon à partir d'une image panchromatique Pléiades et d'images aériennes. Le parcellaire ostréicole y est en effet en constante évolution en raison de l'abandon de certaines zones de production se transformant rapidement en friche. Un outil permettant de détecter les parcelles de culture sur tables et de les différencier des zones en friche serait dès lors particulièrement utile pour le suivi des stocks de production. Les contributions principales de ce chapitre concernent l'étude comparative menée sur différentes approches de représentation de la texture et la confirmation de l'intérêt d'utiliser les modèles multivariés sur des images THR dans ce contexte applicatif particulier. Cette partie de notre

étude a été réalisée en collaboration avec Virginie Lafon de la cellule de transfert GEO-Transfert du laboratoire EPOC de l'Université de Bordeaux.

Les résultats obtenus au cours de ce travail de thèse démontrent le potentiel remarquable des modèles multivariés appliqués sur les sous-bandes d'une décomposition en ondelettes pour la classification d'images satellite à très haute résolution. Ce travail constitue une première tentative d'exploration des performances de ces outils et ouvre de nombreuses perspectives d'utilisation.

# Chapitre I - Méthodes d'analyse de texture appliquées en télédétection : Etat de l'art

<b>I.1 Introduction.....</b>	<b>6</b>
<b>I.2 Notion de texture.....</b>	<b>6</b>
<b>I.3 Méthodes d'analyse de la texture .....</b>	<b>7</b>
<b>I.3.1 Représentation statistique des niveaux de gris.....</b>	<b>8</b>
I.3.1.1 Matrice de co-occurrence des niveaux de gris.....	8
I.3.1.2 Variogrammes.....	14
<b>I.3.2 Analyse fréquentielle de la texture .....</b>	<b>16</b>
I.3.2.1 Transformée de Fourier .....	17
I.3.2.2 Filtres de Gabor .....	18
I.3.2.3 Transformée en ondelettes .....	19
<b>I.3.3 Modélisation probabiliste des sous-bandes d'ondelettes .....</b>	<b>23</b>
I.3.3.1 Distribution Gaussienne généralisée.....	23
I.3.3.2 Modèles multivariés.....	25
<b>I.4 Comparatif des méthodes d'analyse de texture .....</b>	<b>30</b>
<b>I.4.1 Les matrices de co-occurrence comme méthode de référence .....</b>	<b>31</b>
<b>I.4.2 Représentation des sous-bandes d'ondelettes.....</b>	<b>31</b>
<b>I.5 Conclusion .....</b>	<b>32</b>



## I.1 Introduction

Depuis les travaux pionniers menés par [Julesz, 1962], de nombreuses approches ont été développées pour décrire le contenu textural des images. Plusieurs stratégies de caractérisation de la texture ont ainsi été envisagées au cours du temps dans la littérature scientifique en s'appuyant sur l'analyse structurelle de l'agencement des motifs texturaux, sur l'analyse statistique des dépendances spatiales des niveaux de gris, sur le filtrage fréquentiel du contenu de l'image ou encore sur des modélisations probabilistes.

La capacité des images satellitaires optiques à très haute résolution (THR) à discerner les objets géométriques dans le paysage a amené bon nombre d'études à se pencher sur l'utilisation de ces méthodes d'analyse texturale dans des contextes de classification ou de segmentation des images. Dans ce chapitre, après avoir introduit la notion de texture, un état de l'art des principales méthodes d'analyse texturale appliquées au traitement d'images optiques THR est proposé. Le principe général de chaque méthode est détaillé et quelques exemples applicatifs sont présentés. Ensuite, nous nous focalisons sur l'approche au cœur de la méthode proposée dans cette étude en présentant les principaux modèles probabilistes utilisés pour représenter la distribution des coefficients issus des sous-bandes obtenues par décomposition en ondelettes.

## I.2 Notion de texture

Les premières tentatives de définition mathématique d'une texture émanent de recherches menées dans le domaine des neurosciences. Celles-ci se sont intéressées au processus psychophysologique impliqué dans la perception visuelle des textures et permettant à l'œil humain de détecter et de différencier des textures. Un des axes de recherche principal en analyse de textures par traitement d'image consiste à s'inspirer de ce mécanisme de perception visuelle des textures pour le simuler en proposant des représentations mathématiques utilisables dans des algorithmes de traitement automatisés.

Les travaux pionniers menés par Julesz ont ainsi permis d'affirmer que deux textures se distinguent principalement par leurs statistiques d'ordre un et deux [Julesz, 1962]. Le modèle sous-jacent qui permettrait de décrire mathématiquement une texture dépendrait donc uniquement de ces deux statistiques décrivant le comportement spatial des niveaux de gris au sein de la texture. En effet, les statistiques d'ordre un permettent d'évaluer la probabilité d'observer une valeur de niveau de gris dans un pixel de l'image texturée tandis que les statistiques d'ordre deux permettent de décrire la probabilité d'observer une paire de niveaux de gris entre deux pixels de l'image. Cette conjecture a cependant été infirmée ultérieurement par Julesz lui-même en démontrant l'existence de textures partageant les mêmes statistiques d'ordre un et deux mais différant dans leur aspect visuel [Julesz, 1978]. Pour autant, le caractère très spécifique de ces contre-exemples ne remet pas en cause la qualité des statistiques d'ordre deux en termes de pouvoir de discrimination des textures. Ce constat a néanmoins mené les réflexions de Julesz vers une autre théorie d'interprétation de la perception visuelle des textures, la théorie des textons [Julesz, 1981]. Selon cette théorie, une texture serait composée de primitives définies par les propriétés locales de la texture (nombre de terminaisons, longueur, largeur, orientation). La perception humaine de la texture serait dès lors gouvernée par les statistiques d'ordre un de la distribution de ces textons. Cette notion de primitives se retrouve également dans la définition proposée par Haralick selon laquelle une texture peut être décrite par le

nombre et le type de ses primitives ainsi que par l'organisation spatiale ou l'agencement de ces primitives [[Haralick, 1979](#)].

D'autres études en psychophysiologie ont par ailleurs démontré l'aspect multi-fréquentiel de la perception visuelle des textures par le cortex cérébral humain. Ainsi, des expériences menées par [[Campbell & Robson, 1968](#)] ont suggéré la capacité des cellules rétinienne à décomposer une image en plusieurs images filtrées selon différentes fréquences et orientations. Une autre étude a également fait apparaître cet aspect multi-échelles et multi-orientations de la vision en enregistrant les réponses émises par les cellules du cortex visuel primaire de primates, ces réponses s'étant révélées spécifiques à des spectres étroits de fréquences et d'orientations [[De Valois et al., 1982](#)].

### I.3 Méthodes d'analyse de la texture

Les recherches sur la perception visuelle des textures présentées ci-dessus ont contribué à définir les principaux outils d'analyse texturale utilisés couramment en traitement d'image. Ces outils peuvent être classés en quatre grandes catégories [[Tuceryan & Jain, 1998](#)] :

- Les méthodes reposant sur l'**analyse statistique de l'organisation spatiale des niveaux de gris** ont été largement inspirées par les travaux de Julesz. Ces méthodes incluent les matrices de co-occurrence des niveaux de gris [[Haralick et al., 1973](#)], les fonctions d'autocorrélation et les variogrammes [[Curran, 1988](#)].
- Les méthodes dites **géométriques** ou **structurelles** visent à caractériser la texture au travers de l'analyse de la distribution de ses primitives et s'inspirent de la théorie des textons. On y retrouve entre autres les motifs binaires locaux (LBP – *Local Binary Patterns*) [[Ojala et al., 1996](#)].
- Les méthodes basées sur le **filtrage fréquentiel** se réfèrent à la perception multi-fréquentielle de la vision humaine et font appel à des outils de filtrage tels que la transformée de Fourier, les filtres de Gabor [[Manjunath & Ma, 1996](#)] et les décompositions en ondelettes [[Mallat, 1989](#)].
- Les méthodes basées sur des **modèles** cherchent à caractériser statistiquement l'image au moyen de modèles probabilistes en considérant la texture comme une réalisation d'un processus aléatoire. Les modèles Markoviens sont couramment utilisés pour la modélisation de la texture. On retrouve parmi ceux-ci le modèle binomial utilisé pour la synthèse de textures [[Cross & Jain, 1983](#)] ou le modèle de Gibbs pour la segmentation de textures [[Hu & Fahmy, 1992](#)].

La méthode d'analyse texturale sur laquelle repose ce travail de thèse fait intervenir des éléments issus des deux dernières catégories en filtrant tout d'abord la texture par l'application d'une transformée en ondelettes et en modélisant les sous-bandes obtenues par cette décomposition au moyen de modèles probabilistes multivariés.

Parmi les méthodes présentées ci-dessus, celles qui sont les plus couramment utilisées pour la classification et la segmentation d'images de télédétection THR sont décrites et illustrées de quelques exemples applicatifs dans la partie suivante de ce chapitre. On y retrouve essentiellement des

méthodes de représentation statistique des niveaux de gris et des méthodes par filtrage fréquentiel. Les principaux modèles probabilistes utilisés pour représenter les dépendances spatiales des sous-bandes d'ondelettes sont ensuite présentés.

### I.3.1 Représentation statistique des niveaux de gris

Cette catégorie d'approches vise à évaluer la distribution des niveaux de gris contenus dans une texture au moyen de descripteurs statistiques d'ordre deux calculés selon une distance et une orientation entre un pixel central et ses pixels voisins. Parmi les méthodes relevant de cette catégorie, on retrouve régulièrement les matrices de co-occurrence et les variogrammes. Celles-ci dérivent directement de la conjoncture proposée par [Julesz, 1962]. Ces approches sont encore aujourd'hui largement populaires dans la communauté télédétection en raison de la simplicité de leur implémentation et de leur interprétation.

#### I.3.1.1 Matrice de co-occurrence des niveaux de gris

##### A. Principe général

Le calcul d'une matrice de co-occurrence de niveaux de gris ou GLCM (*Grey Level Co-occurrence Matrix*) consiste à repérer dans une image le nombre d'occurrences de paires de niveaux de gris séparés par une distance  $d$  dans une direction définie par un vecteur de déplacement  $(dx, dy)$  [Haralick et al., 1973]. Le calcul de la GLCM pour une image  $I$  de dimension  $N \times M$  se formalise comme suit :

$$GLCM_{dx,dy}(i, j) = \sum_{n=1}^N \sum_{m=1}^M \begin{cases} 1, & \text{si } I(n, m) = i \text{ et } I(n + dx, m + dy) = j \\ 0, & \text{sinon} \end{cases} \quad (1.1)$$

où  $i$  et  $j$  sont les niveaux de gris du pixel de référence et du pixel voisin respectivement,  $n$  et  $m$  correspondent aux coordonnées des pixels dans l'image  $I$ .

On peut déduire de l'équation (1.1) que les entrées situées à proximité de la diagonale de la matrice de co-occurrence seront d'autant plus élevées que les valeurs de niveaux de gris de l'image sont proches ou similaires pour le déplacement considéré. A l'inverse, les entrées hors diagonale seront plus élevées pour des images dans lesquelles les niveaux de gris varient localement pour le déplacement considéré. De même, le contenu textural s'exprimera différemment en fonction de la distance et de l'orientation du déplacement considéré entre les paires de sites. Des exemples de matrices de co-occurrence sont présentés à la Figure 1.1.

En pratique, les entrées de la GLCM sont souvent normalisées en les divisant par le nombre de pixels (somme des entrées égale à 1) afin d'éliminer l'influence de la taille de l'image. En outre, la matrice de co-occurrence est généralement construite de manière symétrique en considérant la somme des entrées calculées pour deux déplacements de directions opposées [Haralick et al., 1973]. Ainsi, pour un déplacement horizontal sur une distance de 1, on intégrera simultanément les occurrences obtenues pour deux vecteurs de déplacement  $(dx, dy)$  égal à  $(1, 0)$  et à  $(0, 1)$ . Notons également l'existence d'une forme généralisée des matrices de co-occurrence dans laquelle les paires d'occurrences sont déterminées à partir des maxima locaux et de l'orientation des gradients autour de ces maxima [Davis et al., 1979]. Cette version généralisée est particulièrement adaptée à la caractérisation de macro-textures.




Figure 1.1 : Exemples de matrices de co-occurrence – (A) forêt, (B) parcelle viticole, (C) zone bâtie, (D) végétation rase. L'échelle à droite des figures correspond au nombre de co-occurrences.

Bien que les GLCMs fournissent une description riche de la dépendance spatiale, il est peu pratique de les manipuler sous leur forme brute. Haralick a ainsi proposé un ensemble de 14 descripteurs statistiques<sup>1</sup> ou attributs permettant de résumer l'information texturale contenue dans les GLCMs [Haralick *et al.*, 1973]. Cependant, seul un sous-ensemble parmi ces 14 descripteurs est régulièrement utilisé. En compilant une série de publications traitant de la classification de textures, [Maillard, 2003] a ainsi identifié les 5 descripteurs d'Haralick apparaissant le plus souvent dans la littérature. Il s'agit de l'énergie, l'entropie, le contraste, la corrélation et l'homogénéité. Par ailleurs, d'autres descripteurs que ceux définis par Haralick peuvent également être dérivés des GLCMs. Il s'agit entre autres de la

<sup>1</sup> Par abus de langage, on utilisera par la suite les termes de statistiques d'ordre deux pour désigner les descripteurs d'Haralick. Le deuxième ordre se réfère ici au fait que les statistiques calculées se basent sur des probabilités d'occurrence d'une paire de niveaux de gris.

Tableau 1.1 : Formulation mathématique des principaux descripteurs dérivés des GLCMs

Energie	$\sum_i \sum_j P_{i,j}^2$	Homogénéité	$\sum_i \sum_j \frac{P_{i,j}}{1 + (i - j)^2}$
Entropie	$\sum_i \sum_j P_{i,j} (-\ln P_{i,j})$	Corrélation	$\sum_i \sum_j P_{i,j} \left[ \frac{(i - \mu_i)(j - \mu_j)}{\sqrt{\sigma_i^2 \sigma_j^2}} \right]$
Contraste	$\sum_i \sum_j P_{i,j} (i - j)^2$	Cluster Shade	$\sum_i \sum_j P_{i,j} (i - \mu_i + j - \mu_j)^3$
Dissimilarité	$\sum_i \sum_j P_{i,j}  i - j $	Cluster Prominence	$\sum_i \sum_j P_{i,j} (i - \mu_i + j - \mu_j)^4$

Où  $P_{i,j}$  = probabilité d'occurrence de la paire de niveaux de gris  $i, j$  (GLCM normalisée),

$\mu_i = \sum_i i P_{i,j}$ , la moyenne des entrées normalisées pour le pixel de référence de valeur  $i$ ,

$\mu_j = \sum_j j P_{i,j}$ , la moyenne des entrées normalisées pour le pixel voisin de valeur  $j$ ,

$\sigma_i = \sum_i P_{i,j} (i - \mu_i)^2$ , l'écart-type des entrées normalisées pour le pixel de référence de valeur  $i$ ,

$\sigma_j = \sum_j P_{i,j} (j - \mu_j)^2$ , l'écart-type des entrées normalisées pour le pixel voisin de valeur  $j$ .

dissimilarité, autre descripteur d'ordre deux proche du contraste, ainsi que de descripteurs d'ordre supérieur à deux tels que le *cluster shade* et le *cluster prominence* [Conners et al., 1984]. Il est à noter que la moyenne et la variance telles que définies par Haralick (soit la moyenne et la variance des entrées de la GLCM pour le pixel de référence) sont aussi régulièrement combinées aux autres descripteurs. La formulation mathématique définissant l'ensemble de ces descripteurs est présentée dans le Tableau 1.1.

La signification statistique des descripteurs présentés dans le Tableau 1.1 peut être décrite comme suit :

- L'**énergie** exprime le caractère régulier de la texture. De manière générale, une énergie élevée est observée lorsque l'image est très régulière, c'est-à-dire lorsque les valeurs élevées de la GLCM sont concentrées à quelques endroits de la matrice. C'est le cas par exemple pour des images dont la distribution des niveaux de gris a soit un aspect constant, soit un aspect périodique. Une image aléatoire ou fortement bruitée produit une GLCM distribuée de manière plus uniforme et présente une énergie faible.
- Le **contraste** est plus élevé pour des GLCMs présentant des valeurs plus larges en dehors de la diagonale, autrement dit pour des images affichant des changements locaux d'intensité. La **dissimilarité** exprime les mêmes caractéristiques de l'image que le contraste à la différence que le poids des entrées de la GLCM augmente linéairement en s'éloignant de la diagonale plutôt que quadratiquement dans le cas du contraste. Ces deux descripteurs sont dès lors souvent corrélés.
- L'**entropie** est d'autant plus élevée que la diagonale de la GLCM est étalée, le cas extrême étant une GLCM uniforme. En ce sens, l'entropie est l'inverse de l'énergie et caractérise l'aspect irrégulier de l'image, d'où une corrélation forte entre ces deux attributs.

- L'**homogénéité** évolue à l'inverse du contraste et prend des valeurs élevées si les différences entre les paires de pixels analysées sont faibles. Celle-ci est donc plus sensible aux éléments diagonaux de la GLCM, contrairement au contraste qui dépend plus des éléments éloignés la diagonale.
- La **corrélation** peut s'apparenter à une mesure de la dépendance linéaire des niveaux de gris dans l'image.
- Le **cluster shade** et le **cluster prominence** donnent des informations sur le degré de symétrie de la GLCM. Plus ceux-ci sont élevés moins la GLCM est symétrique. La symétrie s'entend ici au sens de symétrie globale de la GLCM et pas uniquement de symétrie par rapport à la diagonale de la matrice. De plus, si le cluster prominence est faible, cela signifie qu'un pic existe autour de la moyenne des valeurs de la GLCM et donc qu'il y a peu de variations de niveaux de gris dans l'image.

Une fois calculés et éventuellement normalisés, l'ensemble des descripteurs sont rassemblés dans un vecteur unique caractérisant chaque pixel ou chaque région de l'image. Ce vecteur d'attributs peut ensuite être utilisé comme donnée d'entrée dans un classifieur. Dans le cas d'une analyse pixel-à-pixel, les descripteurs sont souvent représentés sous la forme d'une image pour chaque descripteur calculé.

### *B. Réglage des paramètres*

Une des difficultés majeures rencontrées lors de l'utilisation des GLCMs est le réglage des paramètres. Celui-ci est en effet difficilement automatisable et doit s'adapter au cas par cas aux caractéristiques du motif constituant la texture à analyser. Cet aspect est aussi à mettre en relation avec la résolution spatiale de l'image. Les paramètres à fixer sont la distance entre paires de sites, l'orientation du déplacement, le degré de quantification des niveaux de gris, la taille de la fenêtre d'analyse et le choix des descripteurs texturaux. Une approche régulièrement employée dans cette phase de paramétrisation est de tester différentes combinaisons de ces paramètres afin d'identifier la combinaison la plus optimale. Ces éléments sont discutés ci-dessous.

La **distance** choisie entre paires de sites doit permettre de refléter les corrélations locales entre pixels. Il est souvent admis que ces corrélations sont les plus pertinentes pour de courtes distances et dans la majorité des études, cette distance est fixée à 1. Toutefois, dans certaines applications spécifiques, les objets constitutifs du motif textural (les bâtiments ou les arbres par exemple) ont une taille similaire et la distance choisie est fixée en fonction de caractéristiques propres à ces objets. Ainsi, dans une étude sur la classification de zones urbaines à partir de données IKONOS et QuickBird (résolution spatiale de 1 et 0,6 m respectivement), [[Pacifi et al., 2009](#)] ont choisi une distance de 15 et 30 pixels en se basant sur le constat que les bâtiments de la zone à classer avaient une taille moyenne comprise entre 8 et 24 m. De même, pour détecter des vergers, [[Warner & Steinmaus, 2005](#)] ont déterminé la distance inter-pixels en fonction de la distance moyenne entre les arbres (5 pixels) dans une image IKONOS (résolution spatiale de 1 m).

Typiquement, la GLCM est calculée sur quatre **orientations** différentes (0°, 45°, 90°, 135°) pour la même distance de déplacement selon les recommandations formulées par [[Haralick, 1979](#)] (Figure 1.2). Les descripteurs sont ensuite déterminés sur les quatre matrices obtenues, puis concaténés dans un seul et même vecteur de descripteurs. Toutefois, ce critère d'orientation peut différer dans certaines






Figure 1.2 : Orientations principales considérées pour le calcul des GLCMs.

études où la mise en pratique de la GLCM est opérée soit en fixant le choix de manière arbitraire sur une seule orientation (généralement à  $0^\circ$ ) en l'absence de connaissance *a priori* sur l'anisotropie dominante dans l'image [Franklin *et al.*, 2000 ; Kabir *et al.*, 2010], soit en moyennant les descripteurs obtenus sur les quatre orientations afin d'obtenir un vecteur de descripteurs invariants à la rotation [Kim *et al.*, 2009 ; Maillard, 2003]. L'invariance à la rotation obtenue en moyennant les descripteurs peut être souhaitable dans le cas d'analyse de textures anisotropes. Cette approche réduit en effet la spécificité des descripteurs à une orientation donnée. Néanmoins, cette stratégie est aussi critiquée, notamment dans le cas d'application de détection de zones urbaines [Pesaresi *et al.*, 2008], en arguant que la moyenne des descripteurs sous-exploite le potentiel informatif des GLCMs et diminue dès lors son pouvoir de discrimination.

Le choix de réduire le **nombre de niveaux de gris** de l'image peut être utile pour des questions de rapidité calculatoire liée à la lourdeur de la manipulation des GLCMs. Cependant, l'évolution de la puissance de calcul des ordinateurs justifie de moins en moins cette pratique et dans la plupart des études récentes, la résolution radiométrique native de l'image (typiquement égale à 8 bits ou 256 niveaux de gris) est conservée. Certains cas particuliers nécessitent néanmoins d'adapter ce paramètre. L'utilisation d'une fenêtre d'analyse de petite dimension sur des images de dynamique radiométrique large peut en effet être problématique en raison du faible nombre de co-occurrences observées par rapport au nombre total de niveaux gris de l'image. Le résultat est une GLCM clairsemée aboutissant à des descripteurs peu pertinents. Une réduction du nombre de niveaux de gris dans l'image peut permettre d'améliorer la représentativité de la GLCM, mais cette opération s'accompagne invariablement d'une perte d'information texturale. Une discussion autour de la modification de ce paramètre dans le cas de la classification d'image SAR est présentée dans [Clausi, 2002].

Dans le cas de classification d'image pixel-à-pixel, la sélection de la **taille de la fenêtre d'analyse** a toute son importance. Celle-ci doit être suffisamment grande pour inclure le motif définissant la texture, mais aussi suffisamment petite pour conserver le caractère local de la dépendance spatiale et pour éviter qu'une fenêtre centrée sur un pixel d'une classe ne déborde sur les pixels d'une région appartenant à une autre classe faussant ainsi les performances de classification dans les zones de transition. Il est donc préférable de déterminer une taille de fenêtre optimale. Deux approches sont le plus souvent utilisées. La première consiste à tester un ensemble de valeurs pour ce paramètre et à conserver la taille de fenêtre maximisant les performances de classification [De Martino *et al.*, 2003 ; Franklin *et al.*, 2001 ; Puissant *et al.*, 2005]. Une deuxième approche d'estimation de la taille de fenêtre optimale se base sur la méthode du semi-variogramme [Franklin *et al.*, 2000 ; Johansen *et al.*, 2007]. Celle-ci analyse la dissimilarité moyenne entre les valeurs observées pour plusieurs distances

inter-pixels. La distance à partir de laquelle cette dissimilarité se stabilise peut être considérée comme la taille optimale de la fenêtre (voir paragraphe I.3.1.2).

Le dernier paramètre à prendre en considération concerne le **choix des descripteurs texturaux** les plus pertinents. Il est en effet rare de connaître *a priori* la combinaison optimale de ces descripteurs. En outre, certains d'entre eux peuvent présenter une corrélation élevée et une étape de sélection d'attributs est souvent nécessaire pour éliminer cette redondance. La stratégie la plus courante consiste à déterminer un ensemble plus ou moins large de descripteurs généralement issus de la liste présentée dans le Tableau 1.1 et de sélectionner parmi cet ensemble soit ceux étant le moins corrélés par une analyse en composantes principales [Balaguer *et al.*, 2010 ; Puissant *et al.*, 2005], soit ceux dont la combinaison produit les meilleurs résultats de classification [De Martino *et al.*, 2003 ; Kim *et al.*, 2009 ; Yu *et al.*, 2006].

### C. Exemples applicatifs

La plupart des études faisant appel aux GLCMs se focalisent sur la détection, la classification ou la segmentation de classes d'occupation du sol *a fortiori* caractérisées par un aspect texturé dans les images de télédétection optique à haute ou très haute résolution<sup>2</sup>. Trois grands domaines d'application peuvent être distingués :

- La caractérisation des zones urbaines,
- Les applications forestières,
- Les applications agricoles.

En milieu urbain, la complexité de classification recherchée varie souvent en fonction de la résolution spatiale de l'image à disposition. Dans [Pesaresi *et al.*, 2008], la haute résolution d'images panchromatiques SPOT 5 (5 m) est exploitée pour distinguer les zones bâties du reste de l'occupation du sol au moyen de descripteurs issus des GLCMs. A l'inverse, dans [Pacifi *et al.*, 2009], le niveau de détails offert par des images panchromatiques QuickBird (0,6 m) et WorldView 1 (0,5 m) permet de discerner un ensemble de classes d'occupation du sol plus complexe telles que les zones résidentielles, les zones commerciales, le réseau routier, les parkings, etc. La paramétrisation des GLCMs s'adapte alors à cette résolution et à la taille moyenne des bâtiments dans l'image qui en résulte. Les attributs texturaux des GLCMs sont souvent associés aux bandes spectrales de l'image dans le classifieur notamment pour permettre de distinguer les zones bâties des zones de végétation urbaines (parcs, jardins, etc.) ou périurbaines [De Martino *et al.*, 2003]. Les GLCMs, une fois correctement paramétrées en fonction des caractéristiques de l'image, permettent généralement d'atteindre des taux de détection satisfaisants des zones bâties, la plupart des études rapportant des performances supérieures à 90% de bonne détection.

Les applications forestières utilisant les GLCMs cherchent à atteindre deux principaux objectifs. Le premier concerne la capacité des matrices de co-occurrence à cartographier les massifs forestiers en fonction des espèces dominantes qui les composent. Plusieurs études ont démontré l'intérêt de l'utilisation combinée de données spectrales et de descripteurs issus des GLCMs pour la caractérisation des espèces forestières [Coburn & Roberts, 2004 ; Franklin *et al.*, 2000]. L'autre enjeu

---

<sup>2</sup> Il est également intéressant de noter que de nombreux exemples d'utilisation des GLCMs existent pour la classification d'images SAR. Ce domaine d'utilisation s'éloignant du contexte applicatif de ce travail, il n'est que mentionné ici.



majeur concerne l'utilisation des GLCMs pour l'estimation de variables de structures forestières telles que l'âge des peuplements, la hauteur des arbres, le diamètre des couronnes, la densité des peuplements, etc. [[Champion et al., 2014](#) ; [Kayitakire et al., 2006](#) ; [Ozdemir & Karnieli, 2011](#)]. Cette approche concerne surtout la caractérisation des massifs forestiers mono-spécifiques dans lesquels les arbres d'une même parcelle ont le même âge. Une des difficultés rencontrées dans ce type d'applications concerne la sélection d'attributs texturaux pertinents pour chaque variable à cartographier [[Béguet et al., 2013](#)].

Enfin, en ce qui concerne les applications agricoles, on retrouve quelques études ayant testé avec succès l'application des GLCMs notamment pour la détection de parcelles viticoles et de vergers [[Warner & Steinmaus, 2005](#)], pour la cartographie des zones de labours [[Chehata et al., 2013](#)] ou pour la classification de terres agricoles irriguées [[Balaguer et al., 2010](#)].

### I.3.1.2 Variogrammes

#### A. Principe général

Un variogramme permet de mesurer la corrélation spatiale entre des paires de pixels de l'image séparées par un vecteur de déplacement  $d$  en déterminant la variance de la différence entre les deux valeurs des paires de pixels [[Curran, 1988](#)]. Le variogramme expérimental s'exprime mathématiquement de la manière suivante :

$$\gamma(d) = \frac{1}{2N} \sum_{i=1}^N [z(x_i) - z(x_i + d)]^2 \quad (1.2)$$

où  $z(x_i)$  représente le niveau de gris du pixel  $x_i$ ,  $N$  est le nombre de paires de pixels considérées et  $d$  est un vecteur de déplacement indiquant une distance et une direction. On parle également souvent de semi-variogramme pour qualifier cette grandeur puisqu'en réalité la semi-variance de la différence entre paires de pixels est considérée dans son expression. Traditionnellement, celle-ci est calculée pour un ensemble de déplacements et représentée sous la forme d'un graphe avec le déplacement  $d$  en abscisse et la semi-variance en ordonnée. Cette représentation graphique constitue le semi-variogramme proprement dit (Figure 1.3).

Les variogrammes peuvent être déterminés selon une seule direction ou en moyennant les variogrammes obtenus pour toutes les directions (variogramme omnidirectionnel). Dans ce dernier cas, le nombre de directions considérées peut varier d'une étude à l'autre (par exemple : de  $0^\circ$  à  $150^\circ$  par pas de  $30^\circ$  [[Ruiz et al., 2011](#)], de  $0^\circ$  à  $135^\circ$  par pas de  $45^\circ$  [[Maillard, 2003](#)], de  $45^\circ$  à  $135^\circ$  par pas de  $45^\circ$  [[St-Onge & Cavayas, 1997](#)]). Cette approche omnidirectionnelle s'applique surtout dans le cas de textures isotropes. A l'inverse, pour des textures anisotropes, le choix d'une seule direction peut permettre de conserver l'information d'anisotropie et ainsi de mieux discriminer ces textures [[Trias-Sanz, 2006](#) ; [Warner & Steinmaus, 2005](#)].

Afin de pouvoir caractériser cette représentation empirique de la dépendance spatiale dans l'image, un variogramme théorique est estimé à partir du variogramme expérimental en lui ajustant un modèle paramétrique de type exponentiel ou sphérique (Figure 1.3). De ce modèle théorique peuvent être extraits un ensemble d'attributs caractérisant le comportement du modèle. Les attributs texturaux les

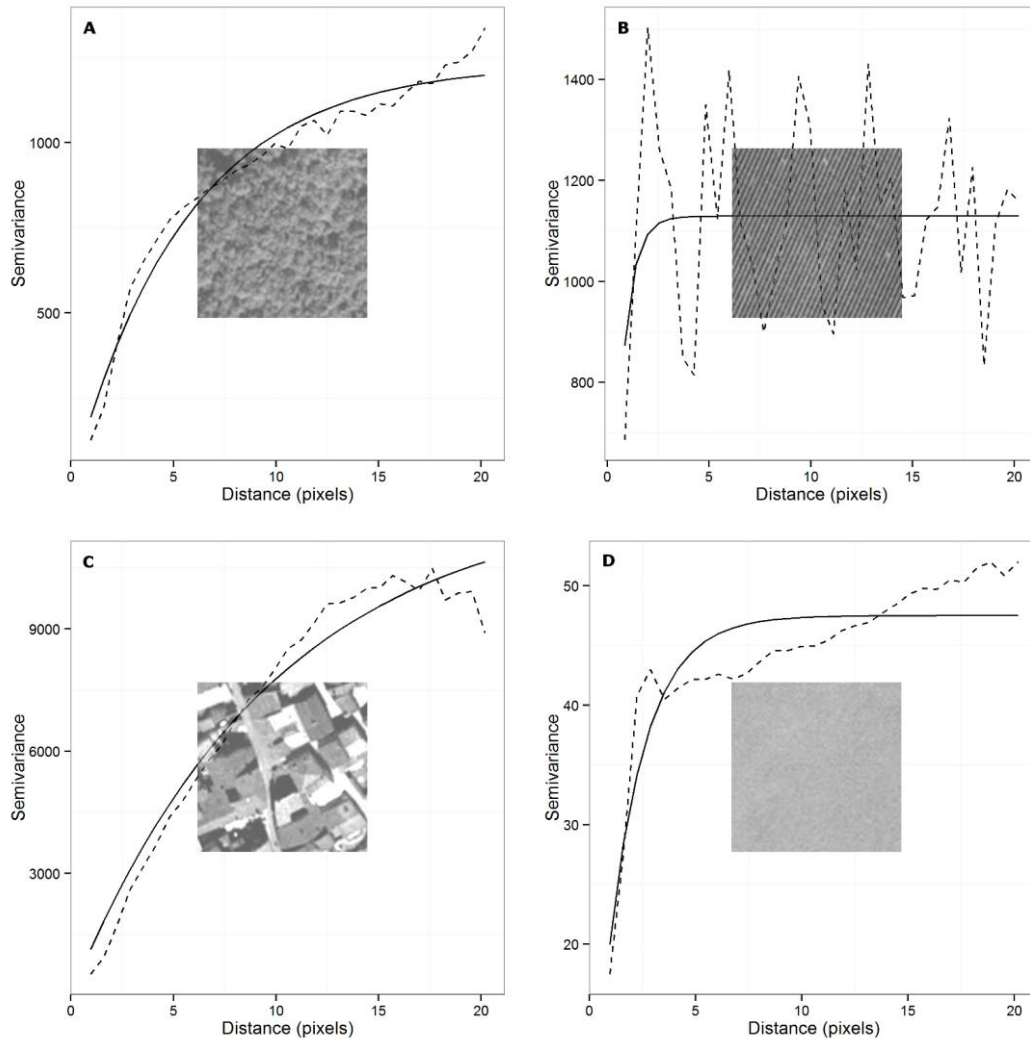


Figure 1.3 : Exemples de semi-variogrammes – ligne pointillée = variogramme expérimental – ligne pleine = variogramme théorique estimée par modèle exponentiel – A forêt, B vigne, C zone urbaine, D végétation rase.

plus couramment utilisés pour caractériser les variogrammes sont les suivants [Curran, 1988] :

- Le **palier** est la valeur maximale de semi-variance atteinte dans le variogramme et peut s'interpréter comme un indicateur de la variabilité spatiale de la donnée.
- La **portée** correspond à la distance à laquelle le palier est atteint. Cela signifie qu'à cette distance, deux pixels sont en moyenne significativement différents. Cet attribut est donc directement lié à la taille des objets ou des motifs constituant une texture. La portée est ainsi régulièrement utilisée pour estimer la dimension optimale de la fenêtre d'analyse ou du voisinage à appliquer lors de l'analyse d'une texture [Franklin *et al.*, 2000 ; Johansen *et al.*, 2007].
- L'**effet pépité** correspond à la semi-variance calculée pour une distance égale à 0. Cette valeur, si elle est supérieure à 0, indique une discontinuité et peut être liée soit à la présence de bruit ou à l'existence de structure spatiale de taille inférieure à celle du pixel.

Tout comme pour les descripteurs des GLCMs, ces attributs peuvent être rassemblés dans un vecteur constituant ainsi une signature texturale utilisable dans des algorithmes de classification ou de segmentation. D'autres types d'attributs issus des variogrammes et répondant à des domaines

d'applications spécifiques sont par ailleurs également proposés dans d'autres études [[Balaguer et al., 2010](#) ; [Maillard, 2003](#) ; [Trias-Sanz, 2006](#)].

### *B. Exemples applicatifs*

L'application des variogrammes en télédétection THR se concentre principalement autour de deux thématiques : la classification ou la caractérisation du couvert forestier et la détection ou la classification de cultures agricoles.

Dans les applications forestières, des attributs texturaux tels que le palier et la portée ont entre autres été utilisés pour l'estimation de variables de structures forestières [[St-Onge & Cavayas, 1997](#)], pour la modélisation de la structure de la canopée [[Lévesque & King, 2003](#)] ou pour la classification de peuplements forestiers d'espèces différentes [[Coburn & Roberts, 2004](#)].

D'autres études en agriculture font appel à des méthodes orientées objet en déterminant les variogrammes sur des régions. Par exemple, [[Balaguer et al., 2010](#)] dérivent un ensemble d'attributs des variogrammes calculés directement à partir du parcellaire cadastral. Ces attributs sont ensuite utilisés dans un algorithme de classification supervisée et permettent de distinguer efficacement différentes zones agricoles. De même, [[Trias-Sanz, 2006](#)] exploite l'aspect périodique caractéristique des variogrammes calculés sur des parcelles de vigne (Figure 1.3 B), des parcelles labourées, des forêts cultivées ou des vergers pour différencier ces classes. Après avoir pré-segmenté l'image et calculé le semi-variogramme sur chaque région obtenue, [[Le Bris, 2012](#)] tire aussi profit de cette périodicité en appliquant une transformée de Fourier sur le variogramme. Si une haute fréquence est détectée, la région correspondante est classifiée en parcelle viticole. D'autre part, une fonction d'auto-corrélation similaire au variogramme est utilisée par [[Warner & Steinmaus, 2005](#)] pour distinguer les parcelles de vignes des vergers en déterminant l'auto-corrélation le long de plusieurs directions. Si des pics apparaissent dans au moins un des auto-corrélogrammes avec un espacement cohérent avec la distance inter-rangs, le pixel appartient à de la vigne ou à des vergers.

De manière générale, l'utilisation du variogramme peut être problématique lors de l'analyse de textures pour lesquelles l'ajustement d'un modèle paramétrique au variogramme expérimental est délicat. Cela est particulièrement visible à la Figure 1.3 pour l'image de vigne par exemple.

## I.3.2 Analyse fréquentielle de la texture

Les recherches en perception visuelle des images ont mis en évidence la capacité du cerveau humain à analyser les images selon leur contenu fréquentiel [[Julesz, 1981](#)]. Les méthodes faisant appel à un filtrage fréquentiel de l'image ont ainsi fait l'objet de bon nombre d'études en analyse texturale appliquée sur des données de télédétection. Cette partie propose un état de l'art de ces méthodes. La plupart d'entre elles se base sur l'extraction d'attributs à partir de l'image transformée par filtrage, attributs exploités ensuite dans des algorithmes de classification ou de segmentation. Les trois approches par filtrage les plus couramment employées sont : la transformée de Fourier, les filtres de Gabor et la transformée en ondelettes.




Figure 1.4 : Exemple d'application de la transformée de Fourier – Image d'origine (gauche), spectre d'amplitude de la transformée de Fourier appliquée sur l'image d'origine (droite).

### I.3.2.1 Transformée de Fourier

La transformée de Fourier  $F$  permet de convertir une image  $I$  de dimension  $N \times M$  depuis son domaine spatial vers son domaine fréquentiel selon la formule suivante :

$$F(u, v) = \sum_{n=1}^N \sum_{m=1}^M I(n, m) \exp \left( -2\pi j \left( \frac{un}{N} + \frac{vm}{M} \right) \right) \quad (1.3)$$

où  $F(u, v)$  est la transformée de Fourier de l'image  $I(n, m)$ . Celle-ci contient une partie réelle et une partie imaginaire. Les deux variables  $u$  et  $v$  désignent les fréquences spatiales de l'image selon les directions  $Ox$  et  $Oy$ . Par convention, on illustre le résultat de la transformée sous la forme d'un spectre d'amplitude représentant le module des valeurs complexes (Figure 1.4). Chaque coefficient de ce spectre correspond à une fréquence observée dans une orientation donnée. Plus on s'éloigne du centre du spectre, plus la fréquence observée est élevée. Ainsi, une texture lisse affichera des valeurs élevées autour du centre du spectre (basse fréquence) alors qu'une texture rugueuse affichera des valeurs plus étalées dans le spectre (haute fréquence).

Dans [Augusteijn et al., 1995], ces caractéristiques du spectre sont exploitées pour classifier différents types de forêts de résineux et de végétations rases en découpant le spectre selon ses coordonnées polaires créant ainsi plusieurs sous-bandes correspondant à divers intervalles de fréquences et d'orientations. Des attributs tels que la moyenne, l'énergie, la variance et la valeur maximum du spectre sont calculés sur chaque sous-partie du spectre.

La transformée de Fourier peut également s'appliquer sur des voisinages locaux. Par exemple, pour discriminer différents stades de développement de la mangrove, [Proisy et al., 2007] déterminent sur des fenêtres de taille croissante un spectre radial en moyennant les coefficients du spectre de Fourier sur toutes les orientations. Une analyse en composantes principales permet ensuite d'identifier l'étendue des fréquences et la taille de fenêtre expliquant au mieux la variabilité. Ces critères sont alors utilisés pour cartographier la mangrove. De manière similaire, [Maillard, 2003] applique une

série de six filtres gaussiens sur des spectres radiaux estimés pour quatre orientations principales (0°, 45°, 90°, 135°) dans un voisinage local de l'image. Des attributs calculés à partir des spectres filtrés sont ensuite utilisés pour classer des images de texture représentant différentes classes (forêt, zones résidentielles, parcelles agricoles, etc.).

La transformée de Fourier se prête particulièrement bien à la détection et à la caractérisation de parcelles viticoles grâce à leur contenu spatial périodique. Ainsi, [Wassenaar *et al.*, 2002] analysent la localisation des pics correspondant à des parcelles viticoles dans l'espace de Fourier pour estimer l'orientation des rangs et la distance inter-rang. [Chanussot *et al.*, 2005] utilise la transformée de Radon appliquée sur la transformée de Fourier pour estimer l'orientation des rangs de vigne et détecter les pieds manquants dans des patches d'images aériennes.

Toutefois, une des principales limites de ce type d'approche est que le spectre de Fourier contient des informations localisées en fréquence et non dans l'espace. L'analyse du spectre ne permet donc pas de déduire directement la localisation spatiale dans l'image des textures dont la réponse fréquentielle est observée dans le spectre. Cette contrainte a mené à l'utilisation d'autres techniques telles que les filtres de Gabor et les transformées en ondelettes fournissant à la fois une localisation fréquentielle et spatiale dans l'image. Ces techniques sont décrites dans les parties suivantes.

### 1.3.2.2 Filtres de Gabor

Les filtres de Gabor ont la capacité de modéliser la sensibilité fréquentielle et directionnelle caractéristique du fonctionnement du cortex visuel humain en décomposant le spectre de l'image en images filtrées selon des plages étroites de fréquences et d'orientations. Un filtre de Gabor est une fonction Gaussienne modulée par une sinusoïde complexe. Dans le domaine spatial, un filtre de Gabor  $h(x, y)$  se définit comme suit :

$$h(x, y) = \frac{1}{2\pi\sigma^2} \exp\left[-\frac{(x^2 + y^2)}{2\sigma^2}\right] \exp(j2\pi F(x \cos \theta + y \sin \theta)) \quad (1.4)$$

où  $\sigma^2$  détermine l'étendue spatiale du filtre. Dans le domaine fréquentiel, après la transformée de Fourier de  $h(x, y)$ , le filtre de Gabor est une surface Gaussienne centrée sur la fréquence  $F$  et l'orientation  $\theta$  :

$$H(u, v) = \exp[-2\pi^2\sigma^2((u - F \cos \theta)^2 + (v - F \sin \theta)^2)] \quad (1.5)$$

Les paramètres qui définissent chacun des filtres sont donc la fréquence  $F$  et l'orientation  $\theta$  autour desquelles le filtre est centré dans le domaine fréquentiel et l'écart-type  $\sigma$  de la Gaussienne.

Une configuration classique de l'utilisation des filtres de Gabor en analyse de texture consiste à faire appel à un banc de filtres, chacun centré sur une fréquence et une orientation distinctes en couvrant au mieux l'ensemble du domaine fréquentiel. Chaque pixel de l'image délivrera ainsi une réponse pour chaque filtre. Une stratégie pour la construction d'un banc de filtres et pour son application est proposée dans [Manjunath & Ma, 1996]. Ces auteurs suggèrent de décomposer le spectre en plusieurs échelles et plusieurs orientations de telle sorte que chaque filtre couvre une portion distincte du demi-spectre en limitant les chevauchements et donc la redondance d'information (Figure 1.5). La moyenne






Figure 1.5 : Exemple de banc de filtres de Gabor appliqué sur le spectre de fréquence avec 4 échelles et 6 orientations par pas de  $30^\circ$

et l'écart-type de la réponse obtenue pour chaque filtre sont ensuite calculés pour déterminer la signature texturale.

L'aspect multi-échelles de cette représentation est particulièrement intéressant lorsque les structures physiques que l'on cherche à identifier dans l'image sont caractérisées par des objets ou des motifs de taille variable. Il est en effet délicat dans ce cas de définir *a priori* une seule échelle d'analyse optimale. De même, la configuration multi-orientations trouve tout son sens dans le cas d'analyse de textures anisotropes et permet de conserver une information de directionnalité dans la signature texturale.

La procédure présentée dans [Manjunath & Ma, 1996] est reprise dans bon nombre d'études en ajustant le nombre d'échelles et le nombre d'orientations au contexte applicatif visé. Par exemple, [Ruiz et al., 2004] ont appliqué un banc de filtres de Gabor pour la classification de zones urbaines et de zones de forêts à partir d'images aériennes et de données QuickBird. [Ma & Majunath, 1998] ont exploré le potentiel de ces outils pour la segmentation d'images aériennes et pour la recherche d'images par leur contenu. [Li et al., 2010] proposent un algorithme de segmentation d'image THR basé sur la théorie des graphes et utilisant un attribut d'énergie de Gabor (plutôt que la moyenne et l'écart-type) comme critère de fusion des régions. Par ailleurs, dans une étude sur la détection des haies dans le paysage agricole [Aksoy et al., 2010], l'invariance à la rotation des attributs issus des filtres de Gabor est obtenue en conservant uniquement la réponse maximale pour toutes les orientations à une échelle donnée. Enfin, [Rabatel et al., 2008] segmentent les parcelles viticoles en ajustant des filtres de Gabor sur les pics du spectre de Fourier. L'image filtrée est ensuite seuillée pour récupérer la ou les parcelles correspondant au pic. Cette méthode de segmentation est exploitée dans le chapitre IV de ce rapport comme méthode de comparaison pour la détection des parcelles viticoles.

### I.3.2.3 Transformée en ondelettes

Malgré la capacité remarquable des filtres de Gabor à décomposer le spectre fréquentiel de l'image, les attributs texturaux extraits de ces filtres peuvent être corrélés en raison de la non-orthogonalité des filtres. Il peut dès lors s'avérer difficile de déterminer si une similarité observée entre échelles d'analyse est due aux propriétés de l'image ou à la redondance inhérente à la représentation. En outre, à chaque échelle d'application des filtres de Gabor, les paramètres définissant ces filtres doivent être modifiés. Ces contraintes sont levées par l'utilisation des ondelettes [Mallat, 1989]. Celles-ci offrent en effet un cadre d'analyse multi-échelles uniforme (une seule paramétrisation pour toutes les




Figure 1.6 : Exemple de décomposition par ondelettes. Image d'origine (gauche), Schéma de décomposition de l'image par DWT avec 2 échelles de décomposition (centre), Résultat de la décomposition (droite).

échelles) et permettent de décomposer l'image en sous-bandes orthogonales et indépendantes limitant ainsi la redondance d'informations.

La transformée en ondelettes décompose l'image en faisant appel à une série de fonctions créées par translation et changement d'échelle d'une fonction d'origine  $\psi$ , appelée ondelette-mère :

$$\psi_{s,u} = \frac{1}{\sqrt{s}} \psi\left(\frac{x-u}{s}\right) \quad (1.6)$$

où  $s$  et  $u$  représentent respectivement le facteur d'échelle et le facteur de translation. La décomposition en ondelettes d'une image  $f(x,y)$  est alors le produit de convolution entre l'image  $f(x,y)$  et les fonctions d'ondelettes  $\psi_{s,u}$  :

$$c_{i,j} = \int_{-\infty}^{+\infty} f(x,y) \frac{1}{\sqrt{s}} \psi\left(\frac{x-u}{s}, \frac{y-u}{s}\right) dx dy \quad (1.7)$$

Cette décomposition permet de calculer les coefficients d'ondelettes  $c_{i,j}$  et autorise également la reconstruction de l'image  $f(x,y)$  à partir des coefficients  $c_{i,j}$ .

En pratique, l'utilisation de la décomposition en ondelettes sur une image discrète à deux dimensions revient à appliquer le produit de filtres passe-haut (H) et passe-bas (L) à une dimension. Dans l'analyse multi-résolutions définie par [Mallat, 1989], une approche de décomposition appelée transformée en ondelettes discrète (DWT) est proposée. Celle-ci consiste à décomposer l'image en quatre sous-bandes sous-échantillonnées d'un facteur 2 (ondelettes dyadiques) à chaque échelle de décomposition. Ces sous-bandes sont le résultat de combinaisons entre filtre passe-haut et filtre passe-bas : LL, LH, HL, HH. La sous-bande LL ou sous-bande d'approximation est une version moyennée de l'image d'origine alors que les sous-bandes HL, LH et HH ou sous-bandes de détails contiennent les hautes fréquences de l'image respectivement dans la direction de  $x$  (horizontale), dans la direction de  $y$  (verticale) ou dans les deux directions  $x$  et  $y$  (diagonale). Pour obtenir le niveau d'échelle de décomposition suivant, la sous-bande LL est à nouveau filtrée et sous-échantillonnée (Figure 1.6). Généralement, l'essentiel de l'information texturale étant lissée par l'application du filtre passe-bas, seules les sous-bandes de détails HL, LH et HH sont exploitées dans l'analyse texturale.

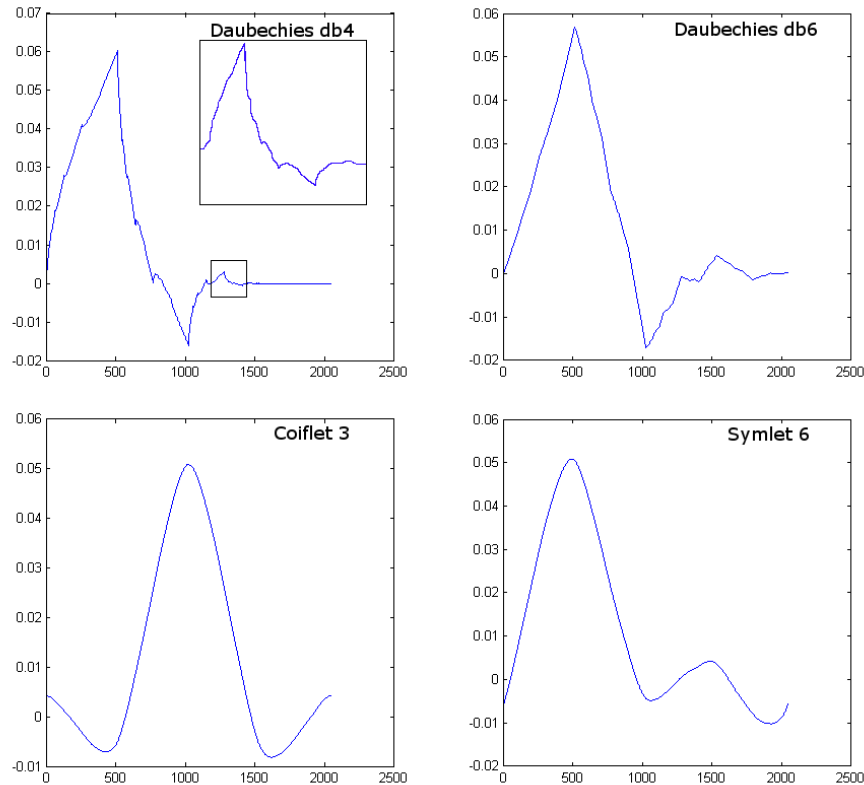


Figure 1.7 : Exemple des différentes familles d'ondelettes. Le nombre à côté du nom de la fonction d'ondelettes correspond au nombre de moments nuls de la fonction. Le graphique haut gauche illustre le caractère quasi-fractal de la fonction *Daubechies db4*.

Plusieurs familles d'ondelettes discrètes peuvent être utilisées. Celles-ci offrent diverses formes de compromis entre régularité de la fonction et aspect plus ou moins compact de son support. Parmi ces familles, les filtres de *Daubechies* [Daubechies, 1992] demeurent l'une des bases d'ondelettes les plus utilisées pour l'analyse de textures en raison de leur propriété quasi-fractale, de la grande variété des fonctions qu'ils autorisent et de l'orthogonalité des sous-bandes produites. Les différents filtres de cette famille sont définis par leur nombre de moments nuls. On parle ainsi de filtres de *Daubechies* 2 (db2), 4 (db4), 6 (db6), 8 (db8), etc. On parle aussi d'ondelettes de *Haar* pour désigner le cas particulier des filtres *Daubechies* à un seul moment nul. D'autres familles de fonctions telles que les *Coiflet* et les *Symlet* sont également régulièrement utilisées et se différencient des filtres de *Daubechies* par leur aspect symétrique et l'étendue de leur support (Figure 1.7).

La DWT (transformée en ondelettes discrète) proposée par [Mallat, 1989] est une méthode standard d'application des ondelettes en analyse de textures. Toutefois, la DWT est limitée en deux points : la sélectivité directionnelle et l'invariance en translation [Selesnik et al., 2005]. Celle-ci ne permet en effet que trois directions d'analyse ce qui peut limiter la capacité de détection de certains contours. Ce constat a mené d'autres chercheurs à proposer de nouvelles formes de décomposition inspirées de la DWT. Citons par exemple la décomposition par paquets d'ondelettes dans laquelle, à chaque échelle, les sous-bandes sont sélectionnées pour la décomposition suivante créant ainsi une extension arborescente de la DWT [Chang & Kuo, 1993] ; la décomposition en ondelettes complexes par arbre dual (DT-CWT) pour laquelle la partie réelle et imaginaire du signal sont décomposées en parallèle selon des filtres distincts permettant de considérer six orientations d'analyse [Selesnik et al., 2005] ; les frames d'ondelettes qui considèrent un facteur de translation continu aboutissant à une sur-



représentation du domaine fréquentiel et à des sous-bandes non-décimées [Unser, 1995]. L'ensemble de ces alternatives à la DWT permettent une meilleure invariance à la translation de la décomposition ainsi qu'à un découpage plus fin dans les orientations considérées. Néanmoins, les sous-bandes obtenues par ces transformations ne sont plus orthogonales et l'information texturale extraite de ces sous-bandes peut être redondante. Plus récemment, des formes adaptatives de la transformée en ondelettes ont également été introduites pour l'analyse de textures orientées ou présentant des caractéristiques géométriques singulières non prises en compte par les transformées classiques (ridgelets [Do & Vetterli, 2003], curvelets [Arivazhagan *et al.*, 2006], contourlets [Po & Do, 2006], etc.).

Dans des applications de classification, la distribution des coefficients d'ondelettes est décrite pour chaque sous-bande en extrayant des attributs tels que l'énergie moyenne, l'entropie [Laine & Fan, 1993] ou des moments d'ordre 3 et 4 (*skewness* et *kurtosis*). Par exemple, [Lucieer & van der Werff, 2007] exploitent ce type d'attributs pour classifier le couvert végétal sur une image QuickBird en appliquant la décomposition sur des fenêtres glissantes et en combinant les attributs obtenus avec les bandes spectrales de l'image. De même, [Fukuda & Hirose, 1999] extraient l'énergie de sous-bandes d'ondelettes non-décimées pour réaliser une classification supervisée d'images SAR polarimétriques acquise sur des zones agricoles. Dans une autre étude, un indice textural dérivé d'un opérateur de détection de lignes est obtenu à partir de sous-bandes d'ondelettes et permet de détecter des parcelles de vigne dans une image aérienne à 0,25 m de résolution [Ranchin *et al.*, 2001].

D'autres auteurs analysent le contenu des sous-bandes en utilisant les descripteurs d'Haralick dérivés de matrice de co-occurrence calculés sur les sous-bandes comme proposé par [Thyagarajan *et al.*, 1994]. Ainsi, [Ruiz *et al.*, 2004] calculent un ensemble de quatre descripteurs (variance, homogénéité, contraste et corrélation) sur chaque sous-bande obtenue par DWT avec 3 échelles de décomposition pour la classification d'images QuickBird acquises sur des zones forestières. Pour une application en classification de zones urbaines, [Ouma *et al.*, 2010] ont adapté la GLCM pour définir un opérateur de détection de crêtes appliqué sur les sous-bandes d'une DWT sur deux échelles. Cette approche de mesure d'attributs de co-occurrence sur ondelettes (*Wavelet Co-occurrence Features* – WCFs dans la suite) a également été testée dans un contexte de recherche d'images par leur contenu dans [Van de Wouwer *et al.*, 1999]. Elle est exploitée dans la suite de ce rapport comme méthode de comparaison au même titre que les GLCMs.

D'autre part, les décompositions en ondelettes sont également exploitées dans des contextes de segmentation d'image [Arivazhagan & Ganesan, 2003 ; Charalampidis & Kasparis, 2002 ; Lo *et al.*, 2007]. Toutefois, ce type d'application concerne surtout des images de textures artificielles et peu d'exemples de segmentation basée sur les ondelettes existent pour les images satellites optiques. Citons néanmoins l'étude menée par [Van Coillie *et al.*, 2008] qui utilise des attributs texturaux issus de sous-bandes d'ondelettes comme critère de fusion ou de séparation de régions pour la délimitation de peuplements forestiers.

L'extraction d'attributs tels que l'énergie ou l'entropie des sous-bandes reste une approche basique de caractérisation de la distribution des coefficients d'ondelettes. Récemment, de nombreuses recherches ont été menées sur l'utilisation de modèles probabilistes afin de caractériser plus finement l'histogramme de cette distribution. Ces approches sont décrites dans la partie suivante.

### I.3.3 Modélisation probabiliste des sous-bandes d'ondelettes

Les modèles probabilistes permettent de caractériser l'information texturale en décrivant de manière paramétrique les distributions marginales ou jointes des coefficients de sous-bandes obtenues par décomposition en ondelettes de l'image. Les paramètres d'ajustement des modèles estimés pour chaque sous-bande sont ensuite utilisés comme signature texturale. L'avantage de cette approche est, comme dans le cas des GLCMs, que les problématiques de classification ou de segmentation d'image peuvent se résumer à des questions de mesures de similarité entre modèles statistiques.

On distingue deux grandes classes de modèles probabilistes :

- Les **modèles univariés** sont utilisés pour modéliser l'histogramme des coefficients d'ondelettes et décrivent les statistiques marginales des sous-bandes. Dans le contexte d'analyse de textures, le modèle univarié le plus courant est la distribution Gaussienne généralisée (GGD) [Mallat, 1989].
- Les **modèles multivariés** décrivent les statistiques jointes des coefficients d'ondelettes et constituent une généralisation des modèles univariés. Ces modèles intègrent la notion de dépendance entre coefficients. Ils sont ainsi utilisés pour décrire la dépendance spatiale entre coefficients voisins d'une même sous-bande ou pour décrire la dépendance entre coefficients issus de différents canaux de l'image (dépendance couleur dans le cas d'une image multispectrale).

Ces deux grandes classes de modèles sont décrites ci-dessous.

#### I.3.3.1 Distribution Gaussienne généralisée

La distribution Gaussienne généralisée (GGD), proposée pour la première fois dans [Mallat, 1989], permet de décrire la distribution des coefficients d'ondelettes dans les sous-bandes haute fréquence de la décomposition. Cette distribution des coefficients est typiquement non-Gaussienne avec une symétrie autour de zéro et un pic centré en zéro (Figure 1.8). La densité de probabilité d'une GGD se définit par l'expression suivante :

$$p(x, \alpha, \beta) = \frac{\beta}{2\alpha\Gamma(1/\beta)} e^{-(|x|/\alpha)^\beta} \quad \alpha, \beta > 0 \quad (1.8)$$

où  $\Gamma(z) = \int_0^\infty e^{-t} t^{z-1} dt$ ,  $z > 0$  est la fonction Gamma. Le paramètre  $\alpha$  représente le paramètre d'échelle de la fonction de densité de probabilité alors que  $\beta$  est un paramètre de forme de la GGD. Ces paramètres peuvent être estimés par maximum de vraisemblance [Do & Vetterli, 2002]. La distribution des coefficients est ainsi modélisée par la GGD en considérant uniquement deux paramètres. La signature texturale obtenue est dès lors particulièrement compacte en comparaison avec l'histogramme complet de la sous-bande.




Figure 1.8 : Modélisation de l'histogramme de sous-bande d'ondelettes par la GGD. Ligne grise : histogramme de la sous-bande (échelle 1 – orientation horizontale). Ligne rouge : GGD ajustée. Dans le cas de la vigne (D), la GGD ne peut être utilisée en raison de l'aspect bimodal de l'histogramme.

Afin de pouvoir comparer les signatures texturales entre elles et ainsi procéder à des opérations de classification de texture, il est nécessaire de définir une mesure de similarité. Une forme analytique de la distance de Kullback-Leibler définie entre deux GGD de paramètres  $(\alpha_1, \beta_1)$  et  $(\alpha_2, \beta_2)$  a été proposée par [Do & Vetterli, 2002] sous la forme suivante :

$$KLD = \log \left( \frac{\beta_1 \alpha_2 \Gamma(1/\beta_2)}{\beta_2 \alpha_1 \Gamma(1/\beta_1)} \right) + \left( \frac{\alpha_1}{\alpha_2} \right)^{\beta_2} \frac{\Gamma((\beta_2 + 1)/\beta_1)}{\Gamma(1/\beta_1)} - \frac{1}{\beta_1} \quad (1.9)$$

Etant donné le caractère non-symétrique de cette divergence, il est usuel de considérer une version symétrique de la KLD appelée divergence de Jeffrey (JD) et définie de la façon suivante :

$$JD = KLD(\alpha_1, \beta_1; \alpha_2, \beta_2) + KLD(\alpha_2, \beta_2; \alpha_1, \beta_1) \quad (1.10)$$

Selon [Van de Wouwer et al., 1999], l'aspect unimodal et la symétrie de l'histogramme des sous-bandes se vérifient dans plus de 98% des histogrammes modélisés à partir d'images de la base de données VisTex [VisTex]. Des résultats de classification par indexation d'images obtenus sur ces données par ces auteurs démontrent la supériorité de la GGD par rapport à un attribut d'énergie calculé sur les sous-bandes. Néanmoins, de nombreux exemples existent pour lesquels la GGD n'est pas capable de s'ajuster correctement à l'histogramme observé. C'est le cas si celui-ci présente un pic légèrement décalé par rapport à zéro ou si sa distribution n'est pas unimodale (Figure 1.8 D). D'autres

modèles univariés généralisant la GGD et offrant plus de flexibilité d'ajustement ont ainsi été proposés. Citons par exemple la distribution Weibull avec deux paramètres d'ajustement [Kwitt & Uhl, 2008] ainsi que la distribution Gamma généralisée [Choy & Tong, 2010] et la Gaussienne généralisée asymétrique [Lasmar *et al.*, 2009], toutes deux caractérisées par trois paramètres. Dans ces études, les modèles cités ont démontré leur supériorité vis-à-vis de la GGD en termes de performance d'indexation d'images sur des bases de données de textures classiques.

Les modèles univariés se prêtent particulièrement bien à la modélisation de la distribution des intensités dans une image SAR et leur utilisation est répandue dans ce domaine avec des applications en débruitage [Argenti *et al.*, 2006], en classification [Gleich & Datcu, 2009] ou en détection de changement [Bazi *et al.*, 2005]. Par contre, on retrouve à ce jour dans la littérature peu d'exemples d'applications de la GGD ou d'autres modèles univariés pour la classification ou la détection de zones texturées dans les images de télédétection optiques. On peut citer néanmoins l'étude menée par [Lefebvre *et al.*, 2011] dans laquelle les paramètres de la GGD sont utilisés pour détecter des parcelles de vigne dans une région viticole sud-africaine (inter-rang égal à 3 m) et estimer l'orientation des rangs dans des images aériennes à 0,5 m de résolution spatiale.

Malgré leur utilisation anecdotique dans les images satellite optiques, les modèles univariés ont montré leur efficacité en classification et indexation de textures à partir de bases de données de textures naturelles [Brodatz ; VisTex]. Cependant, ces modèles ne permettent pas de décrire complètement le comportement statistique des coefficients car ils n'incluent pas d'information sur la dépendance spatiale entre les coefficients. Afin d'exploiter cette information spatiale, des modèles multivariés sont employés pour décrire les distributions jointes des coefficients d'ondelettes.

### I.3.3.2 Modèles multivariés

Plusieurs types de dépendances entre coefficients d'ondelettes peuvent être considérés :

- La dépendance intra-bande (ou **dépendance spatiale**) consiste à analyser la relation entre un coefficient et ses coefficients voisins dans un voisinage défini.
- La dépendance inter-canaux (ou **dépendance couleur** dans le cas d'une image multispectrale) examine la relation entre un coefficient obtenu pour une échelle et une orientation sur un canal de l'image et les coefficients obtenus à la même position spatiale, même orientation et même échelle sur les autres canaux de l'image.
- La dépendance entre un coefficient et le coefficient à la même position spatiale et la même orientation à une échelle différente de la décomposition correspond à la **dépendance inter-échelles**.
- La **dépendance inter-orientations** est celle qui analyse la relation entre un coefficient et son homologue à la même échelle dans une autre orientation.

Dans cette étude, nous nous intéressons essentiellement à celles qui sont le plus souvent exploitées en analyse d'images de télédétection, soit la dépendance spatiale et la dépendance couleur.

Le principe de modélisation multivariée repose sur la description de la distribution jointe des coefficients d'ondelettes dans le sens de la dépendance considérée. Cette distribution jointe est appréhendée au travers d'un ensemble d'observations locales de la dépendance. Si l'on fait l'hypothèse que cette dépendance est un processus aléatoire, chaque observation représente dès lors une réalisation locale de ce processus. Ces observations sont rassemblées dans un vecteur  $\mathbf{k}$  aléatoire.




Figure 1.9 : Dépendance spatiale (gauche) et dépendance couleur (droite) à partir d'une sous-bande d'ondelettes. Les observations locales de dépendance sont rassemblées dans un vecteur  $k$  aléatoire.

Dans le cas de la dépendance spatiale, chaque observation contient l'ensemble des coefficients d'ondelettes présents dans le voisinage d'observation considéré. Classiquement, on choisit un voisinage 3x3 et le vecteur  $k$  a alors une dimension égale à 9. Pour la dépendance couleur, les observations contiennent les coefficients à la même position spatiale dans chaque bande spectrale. Pour une image multispectrale classique (bandes rouge, verte, bleue et proche infrarouge), la dimension du vecteur  $k$  est donc égale à 4 (Figure 1.9).

La distribution de ces observations peut ensuite être modélisée par des modèles multivariés. Plusieurs types de modèles multivariés ont été proposés dans la littérature. Le modèle Gaussien multivarié, la Gaussienne Généralisée Multivariée (MGG), les modèles SIRV (*Spherically Invariant Random Vector*) et les modèles basés sur les copules en font partie.

#### A. Modèle Gaussien multivarié

Si l'on fait l'hypothèse de la Gaussianité de la dépendance à modéliser, le vecteur d'observation  $k$  est un vecteur Gaussien réel de moyenne nulle et de matrice de covariance  $[M]$ . La fonction de densité de probabilité (PDF) du vecteur  $k$  peut alors se définir de la manière suivante [Goodman, 1963] :

$$f(k) = \frac{1}{\sqrt{(2\pi)^p \det[M]}} \exp\left(-\frac{1}{2} k' [M]^{-1} k\right) \quad (1.11)$$

où  $p$  est la dimension du vecteur  $k$ ,  $\det[M]$  le déterminant de la matrice de covariance  $[M]$  et  $k'$  la transposée du vecteur  $k$ . Le processus stochastique Gaussien ainsi défini est uniquement caractérisé par la matrice de covariance. L'estimateur de la matrice de covariance par maximum de vraisemblance, aussi appelé SCM (*Sample Covariance Matrix*), est obtenu en remplaçant la moyenne statistique par une moyenne spatiale calculée sur l'ensemble des  $N$  observations :

$$[\hat{M}] = \frac{1}{N} \sum_{i=1}^N k_i k_i' \quad (1.12)$$

La signature texturale obtenue grâce à ce modèle est dès lors constituée d'une estimation de la matrice de covariance pour chaque sous-bande de la décomposition. Une forme analytique de la divergence de Kullback-Leibler ainsi que de la distance géodésique existent pour cette distribution et permet de comparer les textures modélisées entre elles (voir paragraphe II.2.2.1).

Néanmoins, il est généralement admis que les modèles Gaussiens ne sont pas suffisamment flexibles pour capturer la distribution dite « à queue lourde » des coefficients d'ondelettes. Les autres modèles multivariés (MGG, SIRV et copules) sont des généralisations du cas Gaussien offrant plus de flexibilité d'ajustement que ce dernier.

### B. Gaussienne Généralisée Multivariée (MGG)

Ce modèle généralise la GGD au cas multivarié et est particulièrement adapté pour modéliser la dépendance couleur [Verdoolaege et al., 2008]. La PDF du vecteur  $\mathbf{k}$  dans ce contexte se définit comme suit :

$$f(\mathbf{k}) = \frac{\Gamma(p/2)}{\pi^{p/2} \Gamma\left(\frac{p}{2s}\right) 2^{\frac{p}{2s}} \det[\mathbf{M}]^{\frac{1}{2}}} \times \exp\left(-\frac{1}{2}(\mathbf{k}'[\mathbf{M}]^{-1}\mathbf{k})^s\right) \quad (1.13)$$

où  $\Gamma$  est la fonction Gamma,  $p$  est la dimension du vecteur  $\mathbf{k}$  et  $s$  est un paramètre de forme. Une stratégie récursive d'estimation par maximum de vraisemblance de la matrice de covariance  $[\mathbf{M}]$  et du paramètre de forme  $s$  est proposée par [Verdoolaege et al., 2008] selon les équations suivantes :

$$[\hat{\mathbf{M}}] = \frac{s}{N} \sum_{i=1}^N u^{s-1} \mathbf{k}_i \mathbf{k}_i' \quad (1.14)$$

$$\sum_{i=1}^N \left\{ \frac{s}{2} \ln(u) u^s - \frac{p}{2s} \left[ \ln(2) + \psi\left(\frac{p}{2s}\right) \right] - 1 \right\} = 0 \quad (1.15)$$

où  $\psi$  désigne la fonction Digamma,  $N$  le nombre d'échantillons et  $u$  est défini par  $\mathbf{k}_i'[\mathbf{M}]^{-1}\mathbf{k}_i$ .

La signature texturale extraite des sous-bandes au moyen de ce modèle contient dès lors une estimation de la matrice de covariance et du paramètre de forme pour chaque sous-bande. A défaut d'une forme analytique de la divergence de Kullback-Leibler, [Verdoolaege et al., 2008] ont défini une approximation de la KLD sous la forme d'une distance géodésique de Rao (voir paragraphe II.2.2.1).

### C. Modèles SIRV

Les modèles SIRVs (*Spherically Invariant Random Vectors*) constituent une famille de processus Gaussiens non-homogènes de variance aléatoire [Yao, 1973]. Dans ce contexte, le vecteur aléatoire  $\mathbf{k}$  se définit comme le produit entre un vecteur  $\mathbf{z}$  Gaussien indépendant de moyenne nulle et de matrice de covariance  $[\mathbf{M}]$  et la racine carrée d'une variable scalaire aléatoire positive  $\tau$  appelée multiplicateur :

$$\mathbf{k} = \sqrt{\tau} \mathbf{z} \quad (1.16)$$

Il est intéressant de noter que, selon cette définition des SIRVs, la PDF de la variable aléatoire  $\tau$  n'est pas spécifiée. Par conséquent, les modèles SIRVs peuvent prendre différentes formes et constituent une famille de processus stochastiques. Dans la littérature, plusieurs modèles issus du système de Pearson ont été proposés pour représenter le multiplicateur  $\tau$  (Figure 1.10). Par exemple, pour un




Figure 1.10 : Modélisation de la distribution empirique du multiplicateur  $\tau$  d'un modèle SIRV avec une PDF de Fisher, Gamma et inverse Gamma.

multiplieur distribué selon une loi Gamma, Inverse Gamma ou Fisher, le vecteur aléatoire  $\mathbf{k}$  suit respectivement une distribution K, G0 (SIRVg0 dans la suite) ou KummerU. Si la distribution du multiplicateur est un Dirac, alors la distribution du vecteur  $\mathbf{k}$  suit un modèle Gaussien multivarié (SIRVgauss dans la suite). Un bilan sur l'ensemble des configurations existantes du modèle SIRV est disponible dans [Bombrun *et al.*, 2011a].

La représentation d'une texture par un modèle SIRV n'est pas unique et une étape de normalisation est nécessaire [Gini & Greco, 2002]. En effet, si  $[\mathbf{M}_1]$  et  $[\mathbf{M}_2]$  sont deux matrices de covariance telles que  $[\mathbf{M}_1] = \alpha[\mathbf{M}_2]$  alors  $\{\tau_i, [\mathbf{M}_1]\}$  et  $\{\tau_2 = \tau_i / \alpha, [\mathbf{M}_2]\}$  décrivent le même modèle SIRV. En pratique, la trace de la matrice de covariance est normalisée par  $p$  la dimension du vecteur d'observation  $\mathbf{k}$ . Dans ce contexte, la matrice de covariance normalisée est estimée au moyen d'un estimateur du point fixe (FP) selon l'équation récursive suivante [Pascal *et al.*, 2008] :

$$[\hat{\mathbf{M}}]_{FP} = f([\hat{\mathbf{M}}]_{FP}) = \frac{p}{N} \sum_{i=1}^N \frac{\mathbf{k}\mathbf{k}'}{\mathbf{k}'[\hat{\mathbf{M}}]_{FP}^{-1}\mathbf{k}} \quad \text{avec } \text{Tr}([\hat{\mathbf{M}}]_{FP}) = p \quad (1.17)$$

Pour une matrice de covariance donnée  $[\mathbf{M}]$ , l'estimateur par maximum de vraisemblance du multiplicateur  $\tau_i$  pour le pixel  $i$  est défini par :

$$\hat{\tau}_i = \frac{\mathbf{k}'_i[\mathbf{M}]^{-1}\mathbf{k}_i}{p} \quad (1.18)$$

La distribution empirique de ces estimations du multiplicateur  $\tau$  est ensuite modélisée par la loi univariée choisie (Figure 1.10).

La signature texturale obtenue avec ces modèles est dès lors constituée de l'estimateur FP de la matrice de covariance du processus  $\mathbf{z}$  et des paramètres d'ajustement de la PDF choisie pour représenter la distribution de  $\tau$ . En l'absence d'une forme analytique de la divergence de Kullback-



Leibler, plusieurs stratégies d'estimation des distances entre deux modèles SIRVs ont été proposées. Celles-ci sont présentées dans le paragraphe II.2.2.1.

#### D. Modèles basés sur les copules

Les modèles basés sur les copules sont également une famille de modèles dans lesquels la fonction principale est une fonction de répartition dont les marginales sont uniformes. L'intérêt des copules par rapport aux modèles SIRVs est qu'elles permettent de définir des lois de distributions jointes tout en tenant compte de l'information des lois marginales. Si on considère un vecteur aléatoire d'observations  $\mathbf{k} = [k_1, \dots, k_p]$  de dimension  $p$  avec une fonction de répartition  $F$  et des marginales  $F_1, \dots, F_p$ , alors il existe une copule  $C$  telle que :

$$F(k_1, \dots, k_p) = C(F_1(k_1), \dots, F_p(k_p)) \quad (1.19)$$

Etant donné que la fonction de répartition  $F$  et la copule  $C$  sont continues, la densité jointe  $f(\mathbf{k})$  est donnée par :

$$f(k_1, \dots, k_p) = c(F_1(k_1), \dots, F_p(k_p)) \prod_{r=1}^p f_r(k_r) \quad (1.20)$$

où  $f_r$  est la PDF de  $k_r$  et  $c$  est la densité de la copule  $C$ .

Comme pour les modèles SIRVs, la définition d'une copule ne spécifie pas la loi associée à la fonction de répartition, ni celle associée aux marginales. Plusieurs configurations de copules sont donc possibles. Par exemple, [Stitou *et al.*, 2009] définissent deux types de copules Gaussiennes dont les marginales sont décrites soit par une loi Gamma (Gamma multivariée sur copule Gaussienne), soit par une GGD (GGD multivariée sur copule gaussienne) ; [Lasmar & Berthoumieu, 2014] proposent quant à eux une distribution Weibull multivariée sur copule Gaussienne et dérivent de cette proposition une forme analytique de la KLD ; [Kwitt & Uhl, 2009] présentent une distribution Weibull multivariée sur copule de Student-t et suggèrent une stratégie d'estimation de la KLD pour cette distribution par une approche Monte-Carlo. De cette famille de modèles peut être extraite une signature texturale qui contient l'estimée de la matrice de covariance de la loi multivariée affectée à la copule et les paramètres d'ajustement de la loi univariée choisie pour représenter les marginales.

Dans le cas des copules Gaussiennes, l'estimation par maximum de vraisemblance des paramètres de la distribution peut se faire en deux étapes [Joe & Xu, 1996]. La première consiste à estimer les paramètres  $\hat{\eta} = (\hat{\eta}_1, \dots, \hat{\eta}_p)$  de chaque marginale  $f_1, \dots, f_p$  indépendamment :

$$\hat{\eta}_r = \underset{\eta_r}{\operatorname{argmax}} \log \prod_{r=1}^p f_r(k_{r,i}, \eta_r) \quad (1.21)$$

L'estimation de la matrice de covariance  $[\mathbf{M}]$  est ensuite obtenue dans une seconde étape après avoir transformé l'ensemble des vecteurs d'observation  $\mathbf{k}_i$  en vecteurs Gaussiens  $\mathbf{k}_i^G$  par :

$$\mathbf{k}_i^G = \phi^{-1}(F(\mathbf{k}_{r,i}; \eta_r)) \text{ avec } i = 1, \dots, N \text{ et } r = 1, \dots, p \quad (1.22)$$



où  $\Phi$  est la fonction de distribution cumulative de la distribution Gaussienne normalisée. L'estimateur par maximum de vraisemblance de la matrice  $[\mathbf{M}]$  se définit alors comme suit :

$$[\hat{\mathbf{M}}] = \frac{1}{N} \sum_{i=1}^N \mathbf{k}_i^G \mathbf{k}_i^{G'} \quad (1.23)$$

Plus de détails sur cette procédure sont disponibles dans [Stitou *et al.*, 2009] et dans [Lasmar & Berthoumieu, 2014]. Dans ce travail, nous nous intéresserons uniquement à la Gamma multivariée sur copule Gaussienne (GCG dans la suite) proposée par [Stitou *et al.*, 2009].

### E. Exemples applicatifs

Les modèles multivariés sur sous-bandes d'ondelettes présentés ci-dessus ont essentiellement fait l'objet d'études dans lesquelles sont déterminées leurs performances d'indexation dans un contexte de recherche d'images par leur contenu (CBIR – *Content Based Image Retrieval*) sur des bases de données de textures de référence [VisTex] et [Brodatz]. Ce cadre d'évaluation des performances constitue la norme dans ce domaine [Do et Vetterli, 2002].

A notre connaissance, ces modèles sont encore très peu utilisés pour des applications en analyse d'images optiques de télédétection. Signalons toutefois l'algorithme de segmentation non-supervisée basé sur un mélange de modèles Student-t multivariés et appliqué sur des images multispectrales par [Khan *et al.*, 2014].

Il est par ailleurs intéressant de noter que depuis quelques années, certains de ces modèles gagnent en popularité dans des applications sur des images SAR en utilisant les modèles directement dans l'espace image. Les modèles SIRVs sont par exemple employés pour analyser la dépendance entre les différents canaux d'une image SAR polarimétrique pour l'estimation de la matrice de cohérence [Freitas *et al.*, 2005 ; Vasile *et al.*, 2010] avec des applications en classification et segmentation d'image [Harant *et al.*, 2009]. De même, la dépendance entre les canaux d'une image SAR interférométrique peut être analysée par cette approche multivariée [Vasile *et al.*, 2013]. Les copules ont également été exploitées pour de la détection de changements en analysant les dépendances entre les pixels d'une paire d'images SAR acquises avant et après un événement [Mercier *et al.*, 2008]. Par ailleurs, [Voisin *et al.*, 2013] utilisent des copules pour déterminer la distribution jointe entre l'amplitude d'une image SAR acquise sur une zone urbaine et les images d'attributs texturaux dérivés de la GLCM calculée sur cette image SAR. La signature extraite de ces modèles est ensuite utilisée pour classifier l'image.

## I.4 Comparatif des méthodes d'analyse de texture

Les différentes méthodes d'analyse texturale exposées dans les paragraphes précédents ont fait l'objet de nombreuses études comparatives. Il est toutefois délicat de proposer une hiérarchisation précise de ces approches tant le contexte applicatif, le type de données ou la paramétrisation des méthodes influencent les performances des approches testées. Les matrices de co-occurrence étant très largement utilisées par la communauté télédétection, cette approche sert régulièrement de méthode de référence. Quelques exemples de ces études comparatives et de leurs résultats sont présentés ci-dessous.

### I.4.1 Les matrices de co-occurrence comme méthode de référence

Dans les études basées uniquement sur la représentation statistique des niveaux de gris, les GLCMs ont régulièrement été comparées aux approches de caractérisation de la texture par variogramme. Les conclusions de ces études varient en fonction du contexte applicatif, de la résolution spatiale des données et du choix des paramètres des GLCMs. Ainsi, [[Maillard, 2003](#) ; [Pasher & King, 2010](#)] constatent de meilleures performances de classification avec les GLCMs qu'avec des variogrammes, principalement en raison de leur capacité d'adaptation à la taille du motif de texture en ajustant les dimensions de la fenêtre d'analyse. [[Maillard, 2003](#)] remarque toutefois que les variogrammes peuvent être plus efficaces pour discriminer des textures très similaires alors que les GLCMs fonctionnent mieux lorsque les textures sont visuellement différenciables. A l'inverse, de meilleurs résultats de classification sont obtenus avec les variogrammes dans d'autres études traitant de textures aux motifs périodiques de type parcelle viticole ou verger [[Balaguer et al., 2010](#) ; [Warner & Steinmaus, 2005](#)]. L'aspect périodique du variogramme associé à ces textures pourrait expliquer la supériorité de cette approche, comme cela fût démontré par [[Trias-Sanz, 2006](#)].

Les GLCMs sont également souvent comparées ou combinées aux méthodes d'analyse fréquentielle de l'image telles que les filtres de Gabor et les transformées en ondelettes. De nouveau, les conclusions de ces études varient en fonction du contexte. Par exemple, si [[Newsam & Kamath, 2004](#)] observent des performances supérieures des GLCMs pour la détection de zones urbaines dans des images IKONOS, [[Augusteijn et al., 1995](#)] obtiennent de meilleurs résultats avec les filtres de Gabor pour la classification de forêt à partir d'images Landsat. Par ailleurs, certaines études combinent l'aspect multi-échelles des filtres de Gabor ou des transformées en ondelettes à l'utilisation des GLCMs pour décrire la dépendance spatiale locale. Ainsi, [[Clausi & Deng, 2005](#)] constatent de meilleures performances de classification en combinant les attributs des GLCMs avec des attributs issus des filtres de Gabor centrés sur les moyennes et basses fréquences. D'après ces auteurs, les GLCMs sont en effet plus adaptées pour capter les hautes fréquences alors que les filtres de Gabor se comportent mieux dans les moyennes et basses fréquences. De même, les GLCMs sont régulièrement exploités pour décrire les dépendances spatiales au sein des sous-bandes d'ondelettes [[Thyagarajan et al., 1994](#)] avec de meilleurs résultats que des attributs tels que l'énergie sur les sous-bandes ou l'utilisation de la GGD pour modéliser la distribution de ces sous-bandes [[Van de Wouwer et al., 1999](#)].

De manière générale, les études comparatives montrent que les GLCMs se comportent bien par rapport aux approches fréquentielles. De plus, leur utilisation combinée aux approches fréquentielles s'accompagne souvent d'une amélioration des performances par rapport à l'utilisation des GLCMs dans le domaine de l'image. Ce constat confirme le statut de méthode de référence des GLCMs.

### I.4.2 Représentation des sous-bandes d'ondelettes

Les premières études comparatives ont démontré que l'énergie calculée sur les sorties de filtres de Gabor était un meilleur descripteur de la texture que l'énergie calculée sur les sous-bandes d'ondelettes [[Manjunath & Ma, 1996](#)]. Cependant, dans une étude ultérieure, [[Randen & Husoy, 1999](#)] ont observé des taux d'erreurs de classification plus faibles pour l'énergie sur les sous-bandes d'ondelettes que pour les filtres de Gabor. De manière générale, ces études sous-exploitent la représentation en ondelettes en ne considérant pas l'aspect non-Gaussien de la distribution des coefficients.

Les approches par modélisation stochastique des sous-bandes telles que celles proposées par [Choy & Tong, 2010 ; Do & Vetterli, 2002 ; Kwitt & Uhl, 2008] ont démontré que l'*a priori* non-Gaussien pour décrire les lois marginales de distribution dans les sous-bandes en utilisant des distributions univariées de type GGD, Gamma généralisée ou Weibull généralisée pouvait effectivement apporter un pouvoir plus discriminant à l'utilisation de paramètres de type énergie et entropie calculés sur les sous-bandes d'ondelettes. Par la suite, d'autres auteurs ont généralisé cette approche probabiliste univariée en recommandant l'emploi de modèles multivariés pour décrire la distribution jointe des coefficients d'ondelettes, par exemple la GGD multivariée [Verdoolaege et al., 2008] pour les dépendances couleur ou les modèles SIRVs [Bombrun et al., 2011a] et les copules [Stitou et al., 2009] pour les dépendances spatiales. La plupart des études comparatives dans ce contexte s'appuient sur une procédure d'évaluation des modèles basées sur l'indexation d'images de textures homogènes issues de base de données de textures naturelles [VisTex ; Brodatz]. Une hiérarchisation des performances de ces modèles reste néanmoins complexe étant donnée la variabilité des contextes dans lesquels ils sont testés : dépendance couleur ou dépendance spatiale, ondelettes orthogonales ou non-décimées, classes d'images testées, etc. Dans l'ensemble, ces études démontrent la supériorité des modèles multivariés sur les modèles univariés pour la représentation des sous-bandes d'ondelettes.

## I.5 Conclusion

Dans ce premier chapitre, nous avons établi un état de l'art des pratiques d'analyse texturale appliquées dans un contexte de classification et de segmentation d'images satellite optiques à très haute résolution. De cette revue bibliographique, plusieurs conclusions peuvent être formulées :

- La plupart des études sur la classification ou la segmentation au moyen d'outils texturaux appliqués aux images optiques THR ont recours à des approches de représentation statistiques des niveaux de gris, les matrices de co-occurrence et ses attributs dérivés étant de loin les plus populaires. On retrouve toutefois dans les applications les plus récentes quelques exemples d'utilisation d'outils par filtrage fréquentiel de type filtres de Gabor et transformée en ondelettes principalement pour des objectifs de détection de textures présentant un aspect périodique marqué (vignes, vergers, etc.). La transformée en ondelettes et la modélisation des sous-bandes restent toutefois peu exploitées dans ce domaine applicatif.
- L'aspect multi-échelles de la texture est un critère important de paramétrisation des méthodes d'analyse texturale. Les objets à discriminer dans le paysage peuvent en effet présenter des dimensions différentes et les méthodes employées doivent pouvoir s'adapter à ce contexte.
- Les descripteurs texturaux n'étant pas invariants à la rotation, dans le cas de textures anisotropes, l'orientation principale prise en compte dans la détermination des attributs texturaux a une influence non-négligeable sur la qualité de la classification obtenue. Néanmoins, en fonction de l'objectif de l'étude, la non-invariance à la rotation des attributs peut être une qualité désirable. Ce sera par exemple le cas si l'on veut distinguer plusieurs classes de vigne selon l'orientation de leurs rangs.
- Chaque étude a ses propres spécificités en termes d'objectifs et/ou de caractéristiques de la donnée image. Il est donc délicat de transposer la paramétrisation choisie et les résultats

obtenus d'un contexte à un autre. L'approche utilisée devra donc systématiquement être adaptée en fonction des caractéristiques de l'étude envisagée.

Au vu de ces quelques observations générales, la caractérisation de la texture dans le domaine des ondelettes à l'aide de modèles probabilistes constitue une solution intéressante à la fois en termes d'analyse multi-échelles et multi-orientations de la texture mais aussi par sa capacité à résumer sous une forme compacte les informations contenues dans l'image. Si l'utilisation de cet outil reste anecdotique dans des applications de classification d'image optique de télédétection, les résultats obtenus avec ces modèles sur des bases de données de textures naturelles démontrent le potentiel de ces approches. Ces observations viennent confirmer l'intérêt de tester ces méthodes et d'en évaluer les performances dans un contexte de classification d'images optiques à très haute résolution.

Dans le chapitre suivant consacré aux méthodologies employées, nous introduisons la méthode de recherche d'image par leur contenu et la procédure d'indexation d'images associée. Celles-ci sont utilisées pour évaluer les performances de l'ensemble des modèles testés. Les stratégies de classification supervisée et les classifieurs utilisés sont également détaillés dans le chapitre suivant.



# Chapitre II - Méthodologie

<b>II.1 Introduction .....</b>	<b>36</b>
<b>II.2 Recherche d'images par leur contenu .....</b>	<b>36</b>
<b>II.2.1 Principe général.....</b>	<b>36</b>
<b>II.2.2 Notion de similarité .....</b>	<b>37</b>
II.2.2.1 Mesure de similarité appliquée aux matrices de co-occurrence .....	38
II.2.2.2 Mesure de similarité appliquée aux modèles multivariés.....	38
<b>II.2.3 Evaluation des performances .....</b>	<b>40</b>
II.2.3.1 Taux de reconnaissance moyen .....	41
II.2.3.2 Courbe de Rappel/Précision .....	41
<b>II.3 Classification supervisée.....</b>	<b>42</b>
<b>II.3.1 Stratégies de classification .....</b>	<b>43</b>
II.3.1.1 Avec vérité-terrain.....	43
II.3.1.2 Sans vérité-terrain.....	44
<b>II.3.2 Algorithmes de classification.....</b>	<b>46</b>
II.3.2.1 Méthode des $k$ plus proches voisins .....	46
II.3.2.2 Classification par maximum de vraisemblance .....	47
II.3.2.3 Machine à Vecteurs de Support.....	47
<b>II.3.3 Evaluation des performances .....</b>	<b>49</b>
<b>II.4 Conclusion.....</b>	<b>50</b>

## II.1 Introduction

Dans ce chapitre sont présentés l'ensemble des algorithmes utilisés pour la classification supervisée basée sur les attributs texturaux dérivés des modèles multivariés sur sous-bandes d'ondelettes. Les outils introduits dans ce chapitre sont exploités pour évaluer l'aptitude des modèles multivariés à décrire efficacement les textures d'intérêt. Celui-ci se divise en deux grandes parties.

La première présente une méthode d'indexation d'images basée sur une approche généraliste appelée recherche d'images par leur contenu ou CBIR (*Content Based Image Retrieval*). La CBIR est une technique permettant de rechercher des images en fonction de leur contenu visuel caractérisé par des attributs de couleur, de forme, de texture, etc. Dans notre étude, nous nous intéressons uniquement au contenu textural de l'image en utilisant les modèles probabilistes et les méthodes de référence en analyse texturale définies dans le chapitre précédent. Ce cadre d'analyse est régulièrement employé dans la littérature pour comparer les performances d'indexation de différents modèles de représentation des textures à partir d'une base de données de textures naturelles [[Brodatz](#) ; [VisTex](#)]. La notion de mesure de similarité, notion inhérente à la CBIR, est introduite pour les différentes approches d'analyse texturale testées. Enfin, les indices d'évaluation des performances exploités dans ce contexte y sont également détaillés.

Dans la seconde partie, les algorithmes de classification supervisée orientée-objet sont introduits. Il s'agit dans cette partie de présenter les stratégies envisagées dans le cadre classique d'une classification d'images de télédétection à partir de données d'apprentissage. De même, les indicateurs de performances utilisés dans ce contexte sont également définis.

## II.2 Recherche d'images par leur contenu

### II.2.1 Principe général

La recherche d'images par leur contenu ou CBIR repose sur l'existence d'une base de données de patches<sup>3</sup> d'images ou imagerie dans laquelle chaque patch appartient à une classe connue. Le schéma général d'une analyse par CBIR est présenté à la Figure 2.1. Le déroulement classique de cette analyse se compose de deux grandes étapes : l'extraction d'attributs et la mesure de similarité.

Durant la phase d'**extraction d'attributs**, les signatures texturales de l'ensemble des patches de la base de données sont calculées et stockées. Ces signatures sont déterminées selon la méthode d'analyse texturale choisie. Dans le cas par exemple des matrices de co-occurrence, chaque signature est constituée d'un vecteur contenant les descripteurs d'Haralick calculés pour un patch de la base de données. Dans le cas des modèles probabilistes multivariés, la signature déterminée pour un patch correspond à une matrice de covariance estimée accompagnée le cas échéant d'autres paramètres du modèle (paramètre(s) de forme, paramètre(s) d'échelle, ...) et ce pour chaque sous-bande de la décomposition en ondelettes.

---

<sup>3</sup> Dans notre contexte applicatif de classification supervisée d'images satellite optiques, le terme « patch » désigne une sous-image de dimension fixe extraite de l'image satellite à classifier et caractérisée par un contenu textural homogène représentatif de la classe d'intérêt à laquelle la zone d'extraction appartient.

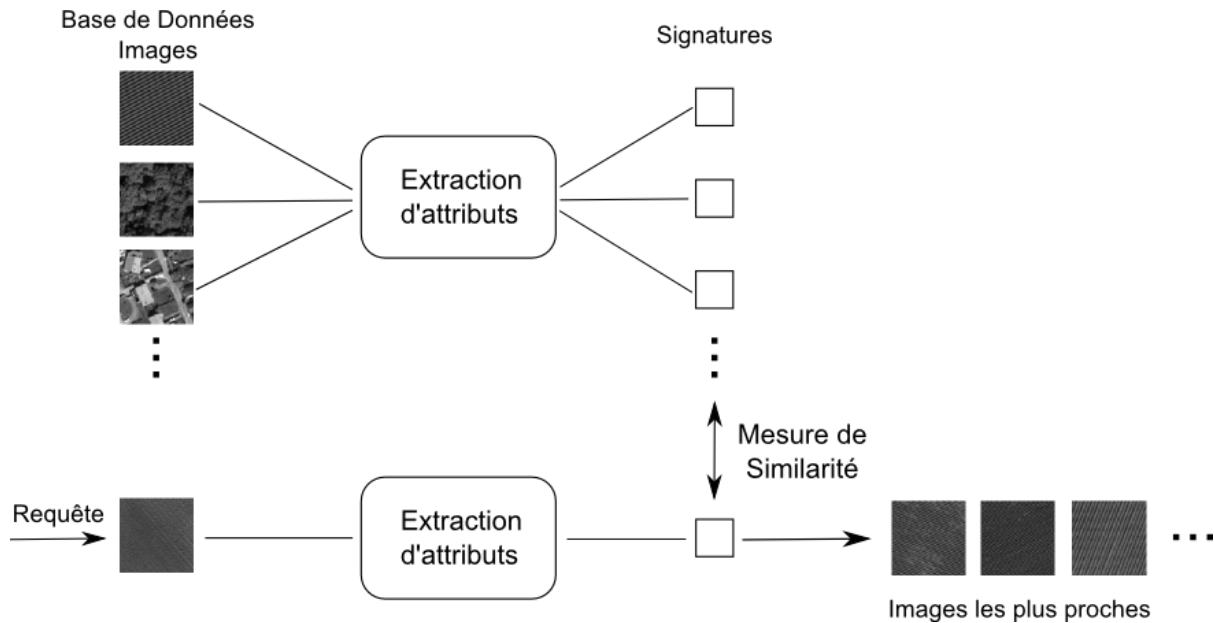


Figure 2.1 : Architecture de la recherche d'images par leur contenu.

La seconde phase consiste à considérer successivement chaque patch de la base de données comme une image requête. Le système récupère la signature de l'image requête calculée lors de la phase d'extraction de paramètres et interroge la base de signatures pour retrouver les patches les plus semblables. Pour ce faire, une matrice de distance est établie en calculant une **mesure de similarité** entre tous les patches de la base de données. Les patches sont ensuite ordonnés en fonction de leur similitude avec l'image requête. La notion de mesure de similarité est donc essentielle à l'utilisation de la CBIR et doit être adaptée à la nature de la signature texturale. Cette notion de similarité est abordée pour chaque approche texturale étudiée dans la partie suivante.

## II.2.2 Notion de similarité

Nous nous proposons d'évaluer les performances d'indexation des modèles multivariés définis dans le chapitre I (voir paragraphe I.3.3.2) et de les comparer aux performances obtenues par la méthode de référence en analyse texturale : la matrice de co-occurrence (GLCM – paragraphe I.3.1.1), ainsi qu'avec les attributs de co-occurrence sur ondelettes (WCFs – paragraphe I.3.2.3). Ces modèles multivariés sont les suivants :

- Le modèle Gaussien multivarié avec un estimateur SCM de la matrice de covariance [**M**] (SCM),
- La Gaussienne Généralisée Multivariée (MGG),
- Le modèle SIRV avec l'estimateur par point fixe de la matrice de covariance (SIRVgauss),
- Le modèle SIRV de distribution G0 (SIRVg0),
- La Gamma multivariée sur copule Gaussienne (GCG).

Afin de comparer les performances de ces différentes techniques, il est nécessaire de définir pour chacune d'elle une mesure de similarité.

Dans le cas des méthodes d'analyse de texture impliquant une décomposition en ondelettes (modèles multivariés et WCFs), il est utile de noter qu'en posant l'hypothèse d'indépendance des sous-bandes,



la similarité mesurée entre deux images  $I_1$  et  $I_2$  correspond à la somme des similarités mesurées entre les paramètres des modèles ou les vecteurs de paramètres issus des paires de sous-bandes  $W_1$  et  $W_2$  de la même échelle  $sc$  et de la même orientation  $or$  :

$$D(I_1 \| I_2) = \sum_{sc=1}^{Nsc} \sum_{or=1}^{Nor} D(W_{1\ sc,or} \| W_{2\ sc,or}) \quad (2.1)$$

où  $Nsc$  et  $Nor$  désignent respectivement le nombre d'échelles et le nombre d'orientations de la décomposition.

### II.2.2.1 Mesure de similarité appliquée aux matrices de co-occurrence

Dans le cas des GLCMs et des WCFs, les descripteurs d'Haralick calculés sur les patches ou sur les sous-bandes sont récupérés sous la forme d'un vecteur. La notion de similarité entre deux images peut dès lors se résumer à une distance entre deux vecteurs dans l'espace des paramètres. Une distance de type euclidienne peut être utilisée dans ce cas. Toutefois, la dynamique des valeurs des différents descripteurs d'Haralick pouvant être variable, il est préférable de normaliser ces attributs. Cette normalisation permet d'imposer la même variabilité pour chacun des descripteurs et donne ainsi le même poids à chacun d'entre eux. On ne privilégie pas un descripteur par rapport à un autre. Si l'on fait l'hypothèse de non-corrélation entre les attributs, la distance euclidienne normalisée mesurée entre deux vecteurs de descripteurs  $\mathbf{x}$  et  $\mathbf{y}$  correspond en réalité à une distance de Mahalanobis pouvant se définir comme suit :

$$d(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{r=1}^p \frac{(x_r - y_r)^2}{\sigma_r^2}} \quad (2.2)$$

où  $p$  est le nombre de descripteurs et  $\sigma_r$  l'écart-type du  $r^{\text{ème}}$  descripteur. Cette distance est utilisée comme mesure de similarité pour les approches par GLCMs et WCFs.

### II.2.2.2 Mesure de similarité appliquée aux modèles multivariés

Pour des applications en indexation d'images texturées à partir de modèles probabilistes, [Do & Vetterli, 2002] ont démontré l'intérêt de l'utilisation de la divergence de Kullback-Leibler (KLD) pour mesurer la similarité entre deux modèles probabilistes  $P(\mathbf{k}; \eta_1)$  et  $P(\mathbf{k}; \eta_2)$ .

$$KLD = D(P(\mathbf{k}; \eta_1) \| P(\mathbf{k}; \eta_2)) = \int P(\mathbf{k}; \eta_1) \log \frac{P(\mathbf{k}; \eta_1)}{P(\mathbf{k}; \eta_2)} d\mathbf{k} \quad (2.3)$$

où  $\eta$  désigne les paramètres du modèle.

Comme la KLD est définie en fonction de la densité de probabilité, elle présente l'avantage d'être invariante à la paramétrisation du modèle, au contraire des distances euclidienne ou de Mahalanobis. La KLD a ainsi été largement plébiscitée pour de nombreuses applications en indexation et classification d'images (par exemple [Choy & Tong, 2010 ; Lefebvre *et al.*, 2011 ; Mathiassen *et al.*, 2002]). Malheureusement, une expression analytique de cette divergence n'existe pas pour tous les modèles multivariés. Certains auteurs ont toutefois proposé de l'estimer numériquement par des

approches de type Monte-Carlo mais cela implique une complexité calculatoire élevée et dissuasive pour certaines applications [Allili, 2012 ; Kwitt & Uhl, 2009]. Une alternative à la KLD couramment proposée est la distance géodésique de Rao (GD) [Bombrun *et al.*, 2011b ; Verdoolaege *et al.*, 2008]. Une GD entre deux points est définie comme la longueur de la courbe la plus courte connectant ces deux points sur une variété Riemannienne. Cette distance initialement proposée par [Rao, 1945] se base sur la matrice d'information de Fisher établie dans l'espace des paramètres d'une famille de distributions statistiques entre deux points caractérisés par les paramètres  $\eta_1$  et  $\eta_2$  des deux modèles à comparer:

$$GD(\eta_1 \parallel \eta_2) = \int_{\eta_1}^{\eta_2} ds = \int_0^1 \sqrt{\sum_{\mu, \nu} g_{\mu\nu} \dot{\theta}^\mu \dot{\theta}^\nu} dt \quad (2.4)$$

où  $\theta$  désigne les hyper-paramètres de la distribution et  $g_{\mu\nu}$  les éléments de la matrice d'information de Fisher. Cette forme de mesure de similarité a été étudiée pour différentes familles de distributions elliptiques univariées [Mitchell, 1988] et plus récemment étendue au contexte des lois elliptiques multivariées [Berkane *et al.*, 1997].

Pour chaque modèle multivarié testé, une forme analytique ou une approximation de la GD sont présentées ci-dessous. Cette distance est privilégiée à la KLD en raison de l'absence d'expressions analytiques de cette dernière pour certains modèles testés. Par ailleurs, certains auteurs ont observé que la GD pouvait conduire à de meilleures performances de classification que la KLD [Lenglet *et al.*, 2006 ; Verdoolaege *et al.*, 2008]. Notons toutefois que dans le cas du modèle GCG, seule une approximation de la KLD est disponible et sera utilisée uniquement dans ce cas.

#### A. Modèles multivariés Gaussiens

Dans le cas Gaussien, les modèles sont uniquement définis par leur matrice de covariance estimée dans notre étude soit par l'estimateur SCM dans le cas du modèle Gaussien multivarié soit par l'estimateur par point fixe (FP) dans le cas du modèle SIRVgauss. La GD entre deux modèles Gaussiens définis par les matrices de covariance  $[\mathbf{M}]_1$  et  $[\mathbf{M}]_2$  de dimension  $p \times p$  peut se définir dès lors comme une distance affine-invariante selon la formule suivante [James, 1973] :

$$GD([\mathbf{M}]_1 \parallel [\mathbf{M}]_2) = \sqrt{\sum_{i=1}^p (\ln \lambda_i)^2} \quad (2.5)$$

où  $\lambda_i$  sont les valeurs propres de  $[\mathbf{M}]_1^{-1}[\mathbf{M}]_2$ .

#### B. Modèles SIRVg0 et MGG

Pour ces modèles, la question de la mesure de similarité est plus complexe que dans le cas Gaussien car elle dépend non seulement de la matrice de covariance mais aussi des autres paramètres de la distribution. Deux stratégies d'approximation de la GD ont été proposées dans la littérature :

- Lorsque que seule la matrice de covariance  $[\mathbf{M}]$  varie entre les deux populations et que les autres paramètres du modèle (forme, échelle, etc.) sont considérés comme fixés,

- Lorsque tous les paramètres du modèle varient entre les deux populations et que les coordonnées géodésiques sont approximés par des lignes droites.

L'expression analytique de la GD pour ces deux stratégies d'approximation est donnée en Annexe 1. Dans la suite de ce rapport, la méthode basée sur l'approximation linéaire des géodésiques est utilisée pour les modèles SIRVg0 et MGG.

Notons que dans le cas des modèles SIRV, une stratégie d'approximation de la KLD a été proposée dans [Lasmar & Berthoumieu, 2010]. Ces auteurs suggèrent de décomposer la KLD pour la loi jointe  $y = (\tau, \mathbf{z})$  comme la somme de la KLD pour la partie Gaussienne  $\mathbf{z}$  et la KLD pour le multiplicateur  $\tau$ . Comme cette dernière admet une forme explicite pour la plupart des modèles univariés considérés dans la littérature (Gamma, Inverse Gamma, Weibull, etc.), la KLD pour la loi jointe  $y$  peut également être obtenue explicitement.

### C. Copules Gaussiennes

A ce jour, il n'existe à notre connaissance aucune forme analytique de la GD pour les modèles à base de copules. De nombreux auteurs se sont ainsi orientés vers la KLD pour comparer les modèles de copules entre eux. En particulier, [Kwitt & Uhl, 2009] ont proposé une stratégie d'approximation de la KLD par une approche de simulation Monte-Carlo. De manière générale, la KLD mesurée entre deux distributions  $f_1$  et  $f_2$  peut s'écrire comme  $D(f_1 \| f_2) = E_{f_1}[\log f_1(\mathbf{x}) - \log f_2(\mathbf{x})]$ . Cette distance peut être approximée en effectuant un tirage aléatoire d'un échantillon  $x_1, \dots, x_n$  à partir du modèle de  $f_1(\mathbf{x})$  et en calculant ensuite :

$$D_{MC}(f_1 \| f_2) \approx \frac{1}{n} \sum_{i=1}^n \log f_1(x_i) - \log f_2(x_i) \quad (2.6)$$

En appliquant ensuite la forme symétrique de la KLD, on obtient :

$$D_{MC}^s(f_1 \| f_2) = 0.5(D_{MC}(f_1 \| f_2) + D_{MC}(f_2 \| f_1)) \quad (2.7)$$

Bien que cette méthode ait été utilisée avec succès dans de nombreuses études, elle nécessite une complexité calculatoire très élevée. Récemment, [Lasmar & Berthoumieu, 2014] ont suggéré une expression analytique de la KLD pour un modèle de copule Gaussienne. Cette dernière s'écrit comme la somme d'une KLD entre deux modèles Gaussiens pour la partie copule et de  $p$  KLD entre deux modèles univariés pour la partie concernant les marginales. La version symétrique de cette mesure de similarité est utilisée par la suite lorsque l'on compare deux modèles de copule.

## II.2.3 Evaluation des performances

Afin de quantifier les performances en recherche d'images par leur contenu, plusieurs critères de performances peuvent être calculés (voir [Müller et al., 2001] pour une vue d'ensemble de ces critères). Parmi ceux-ci, le taux de reconnaissance moyen ou *Average Retrieval Rate* (ARR) est couramment employé dans les études de comparaison de modèles de texture par CBIR. Une autre méthode standard d'évaluation des performances est une méthode graphique représentant la capacité

de convergence du système et appelée courbe de Rappel/Précision. Ces deux approches sont décrites ci-dessous.

### II.2.3.1 Taux de reconnaissance moyen

Ce critère donne une indication de performance moyenne du système. La base de données de patches contient  $N_T$  patches répartis en  $C$  classes contenant chacune  $N_C$  patches. On considère successivement chacun des patches de la base de données comme un patch requête. On recherche ainsi parmi les  $N_C$  patches les plus proches le nombre de patches  $n_q$  appartenant à la même classe  $C$  que le patch de requête. Son expression est donnée par :

$$ARR = \frac{1}{N_T} \sum_{q=1}^{N_T} \frac{n_q(N_C)}{N_C} \quad (2.8)$$

Un modèle est jugé d'autant plus performant que son ARR se rapproche de 100 %. Il est intéressant de remarquer que ce critère donne autant de poids dans la quantification de la performance au patch le plus proche qu'au «  $N_C$  ième » patch le plus proche. Par conséquent, l'ARR peut être sensible à la présence d'outliers dans la base de données. Par ailleurs, dans le cas d'une base de données contenant un nombre différent de patches par classe, la contribution au taux de reconnaissance moyen de la performance de reconnaissance par classe est proportionnelle au nombre de patches de cette classe.

### II.2.3.2 Courbe de Rappel/Précision

Cette méthode graphique d'évaluation des performances fait appel aux indices de rappel  $R$  et de précision  $P$  se définissant comme :

$$R(k) = \text{moyenne} \left( \frac{\text{nombre de patches de la même classe détectés}}{\text{nombre total de patches de la même classe}} \right) = \frac{1}{N_T} \sum_{q=1}^{N_T} \frac{n_q(k)}{N_C} \quad (2.9)$$

$$P(k) = \text{moyenne} \left( \frac{\text{nombre de patches de la même classe détectés}}{\text{nombre total de patches détectés}} \right) = \frac{1}{N_T} \sum_{q=1}^{N_T} \frac{n_q(k)}{k} \quad (2.10)$$

Le paramètre  $k$  correspond ici au nombre de patches les plus proches de l'image requête. Les deux mesures sont déterminées en faisant varier ce paramètre  $k$  entre 1 et  $N_T$ . Cela équivaut à faire varier le seuil de distance entre l'image requête et les autres images de la base de données. Le rappel  $R$  est une fonction croissante de  $k$  et lorsque  $k$  tend vers  $N_T$ ,  $R$  tend vers 1. En effet, en considérant les  $N_T$  images les plus proches, on est sûr de récupérer toutes les images de la classe de l'image requête. A l'inverse, la précision  $P$  est une fonction décroissante de  $k$  et  $P$  tend vers 1 lorsque  $k$  tend vers 1. On est plus précis lorsqu'on recherche uniquement l'image la plus proche de l'image requête. Cette précision tend vers  $N_C/N_T$  (proche de 0) lorsque  $k$  tend vers  $N_T$ . La courbe de Rappel/Précision est obtenue en représentant  $P$  en fonction de  $R$ .

Cette approche d'évaluation graphique des performances des modèles se rapproche de la méthode plus connue de la courbe ROC (*Receiver Operating Characteristic*) représentant le taux de vrais positifs




Figure 2.2 : Exemple de courbes Rappel/Précision. La courbe A est la courbe idéale, les courbes B et C sont des exemples typiques. La courbe B est jugée plus performante que la courbe C.

(précision) en fonction du taux de faux négatifs. Toutefois, comme recommandé dans [Davis & Goadrich, 2006], l'utilisation de la courbe de Rappel/Précision peut être plus informative que la courbe ROC, en particulier lorsque la base de données analysée est déséquilibrée en termes de nombre d'individus par classe. Les bases de données analysées dans notre étude sont effectivement déséquilibrées ce qui justifie le choix de la courbe de Rappel/Précision.

L'intérêt de cette représentation graphique par rapport à un critère global tel que l'ARR est qu'elle permet d'avoir une vue d'ensemble du comportement du modèle dans un contexte de CBIR. Un modèle est jugé plus performant qu'un autre s'il se rapproche le plus du coin supérieur droit du graphe (Figure 2.2 – courbe A). Ce cas idéal correspond à un modèle suffisamment performant pour détecter tous les patches de la même classe que l'image requête lorsque  $k$  est égal à  $N_C$ . Dans l'exemple donné à la Figure 2.2, le modèle décrit par la courbe B est considéré comme plus performant que le modèle de la courbe C. De manière générale, cette courbe donne une information sur la capacité d'un modèle à détecter toutes les images d'une même classe sans devoir parcourir toute la base de données.

## II.3 Classification supervisée

Les modèles multivariés sur ondelettes les plus performants identifiés grâce à l'analyse CBIR sont ensuite évalués dans un contexte de classification supervisée appliquée aux images de télédétection optiques. Par définition, la classification supervisée des images implique une phase d'apprentissage au cours de laquelle les attributs de texture sont extraits d'une série de régions de référence dont on connaît *a priori* la classe. Ces attributs sont ensuite utilisés pour classer un extrait de l'image satellite optique au moyen d'un algorithme de classification établissant les règles de décision. Si une vérité-terrain est disponible sur la zone à classer, une phase de validation peut être réalisée afin d'évaluer les performances du modèle et/ou du classifieur utilisés.

Il existe plusieurs manières d'aborder le problème de la classification basée sur la texture pour traiter des images de télédétection à très haute résolution. L'approche la plus intuitive consiste à déterminer les attributs de texture pixel-à-pixel en faisant appel à une fenêtre d'analyse glissante dans laquelle les

dépendances spatiales sont caractérisées. C'est notamment une approche couramment employée dans l'application des GLCMs aboutissant ainsi à des images de paramètres utilisables comme données d'entrée dans des algorithmes de classification (par exemple [[Béguet et al., 2013](#) ; [Franklin et al., 2001](#) ; [Kabir et al., 2010](#) ; [Warner & Steinmaus, 2005](#)]). Toutefois, cette manière de procéder s'accompagne de quelques inconvénients :

- La taille optimale de la fenêtre d'analyse se détermine difficilement de manière automatique et des tests d'essai-erreur sont souvent nécessaires.
- La très haute résolution spatiale des images s'accompagne généralement d'une forte variabilité locale de la texture. Par conséquent, il est souvent complexe lors de l'apprentissage d'appréhender toute l'étendue de cette variabilité sans avoir besoin d'une large base de données. Cela aboutit généralement à une classification pixélisée requérant l'application de post-traitements.
- Le coût calculatoire d'une analyse pixel-à-pixel sur une image à très haute résolution peut être prohibitif étant donné la résolution des images par rapport aux dimensions des objets à différencier.
- L'utilisation d'une fenêtre glissante peut entraîner des erreurs de classification à proximité des bords de parcelles ou de régions en raison de la présence de textures mixtes.

Pour l'ensemble de ces raisons, nous avons préféré recourir à une approche de classification basée objet plutôt que basée pixel. Une étape de pré-segmentation de l'image est utilisée pour identifier les contours des régions sur lesquelles l'analyse texturale sera effectuée. Cette alternative permet de limiter le nombre d'entités à classer au nombre de régions définies par la segmentation et ainsi de gagner en coût calculatoire et en homogénéité du résultat de classification. La contrainte principale de cette approche reste toutefois le choix de l'algorithme de segmentation et sa paramétrisation.

Dans l'étude que nous avons menée, deux contextes différents de classification ont été rencontrés. Le premier correspond au cas où une donnée de vérité-terrain est disponible. Celle-ci définit une connaissance *a priori* des contours des régions à classer ainsi que du label associé à chacune de ces régions. Dans le deuxième contexte, aucune donnée de vérité-terrain n'est disponible. Pour celui-ci, une pré-segmentation de l'image est opérée pour définir les contours des régions à classer. La stratégie de classification employée a donc été adaptée à ces contextes. Ces stratégies sont présentées ci-dessous.

## II.3.1 Stratégies de classification

### II.3.1.1 Avec vérité-terrain

Le schéma général de cette stratégie de classification est illustré à la Figure 2.3 A. Dans ce contexte, les données de vérité-terrain consistent en une connaissance *a priori* des contours des régions à classer ainsi que de la classe qui leur est associée. Aucune pré-segmentation n'est opérée dans ce cas. Ces données sont valorisées en les utilisant à la fois pour l'apprentissage et pour la validation dans le cadre d'une analyse par validation croisée. Cette approche d'analyse statistique est utilisée ici afin




Figure 2.3 : Schémas de stratégies de classification (A) avec vérité-terrain, (B) sans vérité-terrain.

d'évaluer les performances de classification des différentes approches d'analyse texturale testées et de comparer ces performances dans un contexte pratique de classification.

Dans une première étape, l'extraction des signatures texturales est réalisée sur l'ensemble des régions de la vérité-terrain. Ensuite, à chaque itération de la procédure de validation croisée, les données de référence sont réparties aléatoirement en 50% d'échantillons d'apprentissage et en 50% d'échantillons de validation. Les régions d'une même classe sont distribuées de manière équitable entre les deux séries d'échantillons. Il y a donc autant de régions dans les deux bases de données pour toutes les classes considérées. Les signatures texturales relatives aux échantillons d'apprentissage sont alors utilisées pour classifier les échantillons de validation selon les règles de décision du classifieur employé. Les performances de classification sont ensuite évaluées pour cette itération. Cette procédure est répétée  $n$  fois et des performances moyennes sont déterminées sur l'ensemble des  $n$  itérations.

### II.3.1.2 Sans vérité-terrain

Le schéma général décrivant cette procédure est présenté à la Figure 2.3 B. Dans un premier temps, une base de données de patches d'apprentissage est créée à partir de l'image complète en identifiant par photo-interprétation des zones de texture homogène représentatives des différentes classes de texture à différencier dans la classification. Des patches d'images de dimension identique sont découpés dans ces zones homogènes et rassemblés dans une base de données d'apprentissage. De chacun de ces patches, une signature texturale est extraite selon la méthode d'analyse texturale choisie. Cette étape constitue la phase d'apprentissage de la classification supervisée.






Figure 2.4 : Exemple de résultats de segmentation obtenus par l'algorithme du Mean-Shift. Les lignes vertes désignent les contours des régions. Gauche : Rayon  $r = 5$ , Intervalle de niveaux de gris  $s = 10$ , Taille minimale de région  $t = 500$  pixels. Droite : Rayon  $r = 5$ , Intervalle de niveaux de gris  $s = 5$ , Taille minimale de région  $t = 250$  pixels.

En parallèle, l'extrait de l'image à classifier est préalablement segmenté au moyen d'un algorithme de Mean-Shift [Comaniciu & Peer, 2002]. Cette méthode de segmentation cherche itérativement les maxima locaux dans la distribution de la densité des niveaux de gris. L'algorithme fixe dans un premier temps un nombre défini de points d'initialisation dans l'espace de distribution des niveaux de gris. Pour chaque point d'initialisation, tous les pixels situés dans le cercle de rayon  $r$  autour de ce point et dont la valeur est comprise dans un intervalle de valeurs  $s$  sont pris en compte pour calculer une moyenne locale. L'algorithme estime ensuite localement le gradient de la densité de niveaux de gris et déplace ensuite le point d'initialisation selon ce gradient. La moyenne locale est à nouveau calculée selon cette nouvelle position et le gradient local à nouveau estimé jusqu'à ce qu'un point de convergence soit atteint. Les points de convergence ainsi atteints correspondent aux maxima locaux. Si plusieurs points sont associés au même maximum local, ils sont rassemblés dans la même région.

Plusieurs paramètres sont à fixer pour cet algorithme : la taille du rayon  $r$ , l'intervalle de niveaux de gris  $s$  et un facteur de taille minimale de région  $t$ . Le choix de ces paramètres n'est pas critique tant qu'ils permettent d'aboutir à une image suffisamment segmentée pour éviter la création de régions contenant des textures « mixtes ». Une image sur-segmentée n'a donc pas de conséquences dramatiques si ce n'est le nombre plus élevé de région à classifier. Cette sur-segmentation peut être même souhaitable dans le cas où la taille des objets à classifier est faible. Les deux exemples de résultats de segmentation présentés à la Figure 2.4 ont été obtenus avec des paramètres différents, mais ils devraient permettre d'aboutir à la même classification.

D'autres algorithmes de segmentation auraient pu être choisis pour cette étape, tels que les SLIC (*Simple Linear Iterative Clustering*) [Achanta et al., 2012] ou la segmentation morphologique [Pesaresi & Benediktsson, 2001]. Notons également qu'il pourrait être judicieux d'appliquer cette segmentation directement sur des images de paramètres de texture plutôt que sur l'image en niveaux de gris.



En fonction du classifieur choisi (voir paragraphe II.3.2), l'étape suivante consiste soit à appliquer la même méthode d'analyse texturale que lors de l'apprentissage pour extraire une signature texturale de chaque région, soit à estimer un critère de vraisemblance entre les dépendances observées dans chaque région et les modèles estimés lors de l'apprentissage. Le classifieur sélectionné affecte alors à chaque région une classe selon les règles de décision propres à ce classifieur. Le résultat de classification obtenu est par la suite validé grâce à une vérité-terrain réalisée par photo-interprétation.

## II.3.2 Algorithmes de classification

Trois méthodes de classification supervisée ont été testées dans cette étude : la méthode des  $k$  plus proches voisins ( $k$ -NN), la classification par maximum de vraisemblance (ML) et la classification par Machine à Vecteurs de Support (SVM). Ces trois approches sont détaillées dans les paragraphes suivants.

### II.3.2.1 Méthode des $k$ plus proches voisins

L'algorithme des  $k$  plus proches voisins ou *k-Nearest Neighbors* ( $k$ -NN) est une méthode de classification se basant sur une notion de similarité entre les entités d'apprentissage et les entités à classifier. Son principe est parmi les plus simples des algorithmes de classification. Un objet est classifié selon la classe majoritaire parmi ses  $k$  plus proches voisins où  $k$  est un entier positif.

La notion de similarité repose sur une métrique de distance adaptée à la méthode texturale choisie. Tout comme dans l'analyse par CBIR, elle correspond à une distance de Mahalanobis dans le cas d'attributs texturaux dérivés des GLCMs et à une distance géodésique ou à une divergence de Kullback-Leibler dans le cas des modèles multivariés sur sous-bandes d'ondelettes. Pour classifier une région issue d'une pré-segmentation de l'image ou de la vérité-terrain, une distance est mesurée entre la signature texturale déterminée sur cette région et toutes les signatures texturales calculées lors de l'apprentissage. Les échantillons d'apprentissage sont ensuite triés par ordre croissant de leur distance et la classe majoritaire parmi les  $k$ -NN échantillons est affectée à la région à classifier.

On peut noter que selon cette approche l'échantillon le plus proche et le  $k$ -ième échantillon le plus proche ont le même poids dans la règle de décision. Afin de mieux respecter la hiérarchie des distances, l'algorithme des  $k$ -NN a été ici modifié afin de pondérer les échantillons les plus proches en fonction de leur rang dans les  $k$  plus proches voisins. Le  $i$ -ième échantillon le plus proche aura un poids égal à  $k-i+1$  pour  $i$  variant de 1 à  $k$ . Un score est alors calculé pour chacune des classes en additionnant le poids de chacun des  $k$  plus proches échantillons appartenant à cette classe. La classe ayant le score le plus élevé est affectée à la région à classifier.

Le choix du paramètre  $k$  dépend principalement des données. Généralement, un  $k$  de faible valeur s'accompagne de performances plus élevées (on a plus de chance de ne trouver que des échantillons de la même classe que la région à classifier), mais l'algorithme peut alors être plus sensible à la présence d'individus aberrants. A l'inverse, un  $k$  plus grand peut réduire l'effet lié aux individus aberrants mais entraîner aussi plus d'erreurs de classification (on a moins de chance de ne trouver que des échantillons de la même classe que la région à classifier). Une bonne valeur de  $k$  est donc un compromis entre ces deux risques d'erreurs de classification. Dans cette étude, la valeur du paramètre  $k$  est fixée au cas par cas en fonction de la taille de la classe la moins représentée dans la base de données d'apprentissage.

### II.3.2.2 Classification par maximum de vraisemblance

Le principe général de cet algorithme de classification est le suivant. De chaque région  $q$  à classifier sont extraits un ensemble de  $n$  observations locales de la dépendance à modéliser  $(x_1, \dots, x_n)$ . Un critère de log-vraisemblance  $V_{q,s}$  est ensuite estimé entre ces observations locales et les modèles de dépendance  $p(x; \hat{\theta}_s)$  déterminés pour chaque échantillon  $s$  d'apprentissage :

$$V_{q,s} = \log p(x_1, \dots, x_n; \hat{\theta}_s) \quad (2.11)$$

où  $\hat{\theta}_s$  correspond aux paramètres estimés du modèle pour l'échantillon  $s$ . L'estimateur de vraisemblance est le même que celui utilisé lors de l'estimation des paramètres du modèle pendant l'apprentissage. Ce critère de vraisemblance est déterminé pour chaque sous-bande de la décomposition et sommé sur toutes les sous-bandes pour définir un critère de vraisemblance globale. La classe de l'échantillon qui maximise ce critère de vraisemblance est alors affectée à la région à classifier.

L'avantage de la classification par maximum de vraisemblance par rapport au  $k$ -NN est qu'elle ne nécessite pas de ré-estimer les paramètres d'un modèle pour chaque région à classifier. Cela peut être utile dans le cas où ces régions sont de faibles dimensions et ne comportent pas suffisamment d'observations locales de la dépendance pour déterminer un modèle stable de cette dépendance. Toutefois, le coût calculatoire de l'estimation du critère de vraisemblance peut être élevé en particulier lorsque le nombre de régions est important.

### II.3.2.3 Machine à Vecteurs de Support

Les Machines à Vecteurs de Support appelées aussi Séparateur à Vaste Marge ou *Support Vector Machine* (SVM) ont été introduites dans [Boser et al., 1992] et plus largement développées dans [Vapnik, 1995]. L'utilisation des SVMs a connu une popularité grandissante ces dernières années dans des applications de classification ou de régression à partir d'images de télédétection [Mountrakis et al., 2011]. Cette popularité provient essentiellement de la capacité des SVMs à fournir de bons résultats de classification même lorsque le nombre d'échantillons d'apprentissage est faible, une contrainte récurrente dans les applications en télédétection. Ils surpassent souvent aussi les performances produites par des classifieurs traditionnels tels que l'approche par maximum de vraisemblance [Mantero et al., 2005 ; Pal & Mather, 2005]. L'avantage dont bénéficient les SVMs est leur propriété de minimisation des risques d'erreur de classification même sans connaissance *a priori* sur la distribution des données. Par ailleurs, la possibilité d'adapter le noyau aux caractéristiques des données sans pour autant changer le principe général du classifieur fait des SVMs un outil de classification particulièrement flexible.

Le principe général des SVMs est basé sur la recherche d'un hyperplan permettant de séparer des observations tout en maximisant la marge, c'est-à-dire la distance du point le plus proche à l'hyperplan. L'hyperplan optimal est une solution unique et peut être déterminé au moyen d'un nombre de points limites appelés « vecteurs de support » (Figure 2.5). La discrimination entre deux classes par la recherche d'un hyperplan optimal ne peut souvent se faire que dans un espace où les données sont linéairement séparables. Une transformation non-linéaire au moyen d'un noyau permet de projeter les données dans un espace de plus grande dimension dans lequel la recherche de l'hyperplan est rendue possible (SVM non-linéaire). Un noyau est une fonction  $K$  qui associe à tout




Figure 2.5 : Exemple de fonctionnement du SVM dans le cas linéaire. Seuls 4 vecteurs de support sont nécessaires pour définir l'hyperplan optimal.

couple d'observations  $(x, x')$  une mesure de leur influence réciproque au travers de leur corrélation ou de leur distance. Deux exemples classiques de noyaux sont le noyau polynomial et le noyau Gaussien :

$$K(x, x') = (\langle x, x' \rangle + 1)^p \quad (2.12)$$

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right) \quad (2.13)$$

où  $p$  le degré du polynôme et  $\sigma$  l'écart-type du noyau Gaussien sont des paramètres à fixer. Le noyau Gaussien reste toutefois le plus régulièrement employé et a largement démontré son utilité, même en comparaison du SVM linéaire [Keerthi & Lin, 2003]. Dans cette étude, le noyau Gaussien est adapté à la mesure de similarité associée aux modèles utilisés en remplaçant la distance euclidienne  $\|x - x'\|^2$  par la KLD et la distance géodésique, comme suggéré respectivement dans [Vasconcelos *et al.*, 2004] et dans [Jayasumana *et al.*, 2013].

Toutes les opérations impliquant les SVMs ont été réalisées au moyen de la bibliothèque LIBSVM [Chang & Lin, 2011]. Dans cette implémentation des SVMs, la recherche des hyperplans pour plus de deux classes se déroule par une approche binaire en considérant chaque couple de classes deux à deux définissant ainsi  $c(c - 1)/2$  hyperplans où  $c$  est le nombre de classes. Les mesures de distances obtenues entre les échantillons d'apprentissage des deux classes considérées sont exploitées pour définir le noyau Gaussien. Une fois projetés dans ce nouvel espace, les échantillons d'apprentissage permettent d'identifier l'hyperplan optimal entre les deux classes analysées. Le même paramètre  $\sigma$  du noyau Gaussien est utilisé pour tous les couples de classes. Ces étapes constituent la phase d'apprentissage des SVMs.

Lors de la classification proprement dite, l'échantillon à classer est projeté dans l'espace transformé défini pour chaque couple de classes. Une probabilité d'appartenance à l'une des classes est alors estimée en fonction de la distance entre l'échantillon à classer et l'hyperplan défini par les vecteurs de support. Les probabilités ainsi estimées sont ensuite cumulées pour chacune des classes. La classe maximisant la probabilité est alors affectée à l'échantillon.

### II.3.3 Evaluation des performances

Les classifications obtenues sont évaluées de manière classique en les comparant avec les données de vérité-terrain au moyen d'une matrice de confusion et des indices de précision de classification associés. La matrice de confusion se construit comme suit. Les colonnes représentent les classes des régions dans la vérité-terrain et contiennent la répartition des régions en fonction de leur classe dans le résultat de classification. Les lignes représentent à l'inverse les classes des régions dans la classification et contiennent leur répartition en fonction de leur classe dans la vérité-terrain. La diagonale de la matrice contient ainsi le nombre de bonnes classifications et tous les éléments situés hors de la diagonale correspondent aux erreurs de classification.

Des indices dérivés de la matrice de confusion permettent d'évaluer la précision globale et la précision par classe de la classification. Ces indices sont les suivants [Congalton, 1991] :

- La précision globale ou *Overall Accuracy* (OA) indique le pourcentage de bonnes classifications par rapport au nombre total des régions à classer. Elle s'appuie sur la somme des éléments de la diagonale de la matrice de confusion normalisée par  $N$  le nombre total de régions :

$$OA = \frac{1}{N} \sum_{i=1}^C n(i, i) \quad (2.14)$$

où  $C$  le nombre de classes et  $n$  les entrées de la matrice de confusion.

- La précision du producteur ou *Producer's Accuracy* (PA) est la probabilité pour une région appartenant à une certaine classe dans la vérité-terrain d'être correctement classifiée. Il s'agit donc contrairement à l'OA d'un indice de précision par classe. Elle est obtenue pour la  $j$ -ème classe par :

$$PA_j = \frac{n(j, j)}{\sum_{i=1}^C n(i, j)} \quad (2.15)$$

et équivaut donc au nombre de régions de la  $j$ -ème classe correctement classifiée divisé par la somme sur la  $j$ -ème colonne de la matrice de confusion. Cette mesure correspond à une forme d'indice de confiance que le producteur de la classification peut accorder à sa méthode de classification.

- La précision de l'utilisateur ou *User's Accuracy* (UA) est la probabilité pour une région classifiée dans une certaine classe d'effectivement appartenir à cette classe selon la vérité-terrain. Elle est obtenue pour la  $i$ -ème classe par :

$$UA_i = \frac{n(i, i)}{\sum_{j=1}^c n(i, j)} \quad (2.16)$$

et équivaut donc au nombre de régions de la  $i$ -ème classe correctement classifiée divisé par la somme sur la  $i$ -ème ligne de la matrice de confusion. Cette mesure correspond à une forme d'indice de confiance que l'utilisateur de la carte produite peut accorder à cette carte.

- L'indice Kappa [Cohen, 1960] est un indice global de précision de classification différant de l'OA car tenant compte de la proportion  $P_h$  de bonnes classifications potentiellement dues au hasard. Il s'exprime comme suit :

$$\kappa = \frac{OA - P_h}{1 - P_h} \quad \text{avec } P_h = \frac{1}{N^2} \sum_{i=1}^c n(., i), (i, .) \quad (2.17)$$

où  $n(., i)$  et  $n(i, .)$  désignent respectivement les sommes sur la  $i$ -ème colonne et la  $i$ -ème ligne. Plus l'indice Kappa se rapproche de 1, plus la concordance entre vérité-terrain et classification est forte. Autrement dit, un Kappa de 0.75 signifie que 75% des bonnes classifications ne sont pas dues au hasard.

## II.4 Conclusion

Ce chapitre s'est essentiellement intéressé à l'exposé des méthodologies mises en œuvre dans cette étude pour deux types d'analyses principales : (1) la comparaison des performances en reconnaissance de textures des différentes approches d'analyse texturale envisagées et (2) les stratégies de classification supervisée.

Pour la première problématique, la procédure généraliste de recherche d'images par leur contenu (CBIR) a été présentée et la notion de similarité inhérente à cette démarche a été définie pour l'ensemble des méthodes à comparer. Cette approche sera exploitée dans les chapitres suivants pour identifier les modèles les plus performants en fonction de la thématique applicative. Les modèles ainsi identifiés sont ensuite évalués dans un contexte plus applicatif de classification supervisée orientée objet. Différentes stratégies de classification ont été décrites dans la seconde partie de ce chapitre en fonction de la disponibilité de données de référence terrain. Enfin, plusieurs techniques de classification supervisée ont été introduites ( $k$ -NN, maximum de vraisemblance et SVM).

La principale contribution de notre travail proposée dans ce chapitre relève des deux stratégies de classification ainsi que des chaînes de traitement associées à ces deux stratégies présentées à la Figure 2.3 et détaillées dans le paragraphe II.3.1.

Dans les chapitres suivants, les méthodologies exposées ici seront appliquées sur des images satellite optiques à très haute résolution dans trois thématiques principales : la classification de classes d'âge de peuplements forestiers mono-spécifiques (chapitre III), la détection de parcelles viticoles (chapitre IV) et la détection de tables ostréicoles (chapitre V).

# Chapitre III - Application à la différenciation de classes d'âge de forêt de pin maritime

<b>III.1 Introduction .....</b>	<b>52</b>
<b>III.2 Site d'étude et données .....</b>	<b>53</b>
<b>III.2.1 Le massif de la forêt des Landes de Gascogne .....</b>	<b>53</b>
<b>III.2.2 Site d'étude et données satellite .....</b>	<b>54</b>
<b>III.2.3 Bases de données de patches de texture.....</b>	<b>57</b>
<b>III.2.4 Données de référence de classes d'âge .....</b>	<b>59</b>
<b>III.3 Indexation par CBIR.....</b>	<b>60</b>
<b>III.3.1 Stratégie d'application des méthodes.....</b>	<b>60</b>
III.3.1.1 Réglage des paramètres de la matrice de co-occurrence .....	60
III.3.1.2 Configuration de la transformée en ondelettes.....	62
<b>III.3.2 Résultats d'indexation .....</b>	<b>63</b>
<b>III.4 Résultats de classification .....</b>	<b>68</b>
<b>III.4.1 Résultats obtenus par <math>k</math>-NN .....</b>	<b>69</b>
<b>III.4.2 Résultats obtenus par SVM .....</b>	<b>74</b>
<b>III.5 Conclusions et perspectives.....</b>	<b>76</b>
<b>III.5.1 Conclusions.....</b>	<b>76</b>
<b>III.5.2 Perspectives .....</b>	<b>77</b>

### III.1 Introduction

Dans les forêts mono-spécifiques cultivées, la structure spatiale de la forêt varie dans le temps à l'échelle du peuplement<sup>4</sup> en raison des diverses opérations culturales appliquées au cours de la croissance des arbres par les gestionnaires forestiers. Dans le cas de la forêt des Landes de Gascogne, objet de cette étude, l'itinéraire technique adopté dans la gestion des peuplements de pins maritimes suit un schéma général stable afin d'optimiser la production de bois (Figure 3.1).

En raison de ce cycle bien établi de gestion forestière, il est possible de considérer l'existence d'une corrélation entre les variables de structure forestière (âge, diamètre de la couronne, hauteur d'arbre, densité du peuplement, etc.) et la distribution spatiale des arbres pour des applications de classification d'image à Très Haute Résolution (THR). Cette stratégie a déjà été investiguée dans plusieurs études en faisant appel aux descripteurs de texture dérivés des matrices de co-occurrence pour la classification de variables de structure forestière, comme par exemple dans une forêt mono-spécifique cultivée d'épicéas [[Kayitakire et al., 2006](#)], dans une forêt mixte d'essences de peuplier [[Lévesque & King, 2003](#)] et dans le même contexte que le nôtre en forêt cultivée de pins maritimes [[Béguet et al., 2014](#) ; [Champion et al., 2014](#)]. La thèse de Benoît Béguet s'est déroulée en parallèle des travaux présentés dans ce rapport et s'inscrit également dans le cadre du projet STELLA THR. Elle se concentre sur les stratégies de sélection de descripteurs texturaux issus des matrices de co-occurrence dans un contexte multi-échelles pour la cartographie des variables de structure forestière dans des images satellitaires THR.

Des cartes de variables de structure forestière sont régulièrement produites par les autorités publiques en charge de la gestion de la ressource forestière à des fins d'inventaire. Cependant, la procédure employée peut être lourde car basée principalement sur l'interprétation visuelle des données de télédétection. A l'échelle régionale, la production automatisée de cartes de variables de structure forestière par des approches d'analyse texturale peut constituer une réponse intéressante au suivi des surfaces forestières. En outre, les responsables de la filière bois peuvent également trouver dans ces cartes un outil d'aide à la décision pour le suivi des stocks de bois et l'estimation des productions futures.

Dans ce chapitre, nous proposons d'évaluer le potentiel des modèles multivariés basés sur la décomposition en ondelettes pour la classification des âges de peuplements forestiers et de comparer les résultats avec ceux obtenus par les matrices de co-occurrence. Dans la partie suivante sont décrits le site d'étude, les données satellite THR utilisées ainsi que les données de référence terrain. Les résultats sont ensuite présentés et discutés en deux parties. La première est consacrée à la comparaison des modèles de texture dans un contexte d'indexation d'images à partir d'une base de données de patches de texture. Dans la seconde, les résultats de classification supervisée obtenus sur différentes données satellite à partir d'une donnée de référence sont décrits.

---

<sup>4</sup> Dans cette application, une distinction est faite entre « parcelle » et « peuplement ». Une parcelle au sens cadastral du terme peut en effet contenir plusieurs peuplements. Un peuplement désigne ici une population d'arbres de même âge.






Figure 3.1 : Schéma d'itinéraire technique pour la gestion des peuplements de pins maritimes [Merzeau, 1995].

## III.2 Site d'étude et données

Dans cette partie, les spécificités de l'itinéraire cultural pratiqué dans la forêt des Landes de Gascogne sont décrites dans un premier temps. Les données d'imagerie satellite THR utilisées dans cette étude sont ensuite détaillées en pointant les différences en termes de résolution spatiale et de géométrie d'acquisition entre les images et entre les capteurs Pléiades et GeoEYE. A partir de ces images satellite, des bases de données de patches de texture sont créées en considérant différentes classes d'âge de peuplement. Ces bases de données de patches sont exploitées dans l'analyse d'indexation. Enfin, une seconde base de données appelée « base de données de référence » est également présentée. Celle-ci contient des données d'âge de peuplements recueillies sur le terrain et est exploitée pour la classification.

### III.2.1 Le massif de la forêt des Landes de Gascogne

Situé dans le Sud-Ouest de la France (Figure 3.2), ce vaste écosystème forestier d'approximativement un million d'hectares constitue le premier massif cultivé d'Europe. L'espèce cultivée dominante y est le pin maritime (*Pinus pinaster*) qui recouvre environ 90% de la surface boisée du massif. Cette essence y est cultivée majoritairement par des propriétaires privés pour la production de bois. Ces cultures de pins maritimes sont organisées en peuplements mono-spécifiques d'âge uniforme variant entre 0 (coupe-rases) et approximativement 50 ans. L'organisation spatiale est morcelée avec des superficies de peuplements allant de quelques hectares à plus ou moins 80 hectares.

L'itinéraire technique de gestion forestière tel qu'il est pratiqué dans le massif suit un cycle relativement constant (Figure 3.1). Ainsi, après 2 à 3 années de repos et des travaux de nettoyage de la parcelle (dessouchage et labour), les coupe-rases sont remises en culture. Lors de cette phase de reboisement, la surface est semée ou plantée de jeunes pousses d'arbres (1500 arbres/ha) suivant une structuration en rangs (inter-rangs de l'ordre de 4 à 5 mètres) pour des raisons pratiques de circulation des engins dans les parcelles. Au fur et à mesure de la croissance du peuplement, le couvert végétal se






Figure 3.2 : Localisation du site d'étude. L'image en bas à droite indique l'étendue de la forêt des Landes de Gascogne. Les zones encadrées en couleur dans l'image centrale correspondent aux emprises des images satellite acquises sur la zone d'intérêt.

densifie, les couronnes s'élargissent et la canopée se referme progressivement. Une première éclaircie est réalisée avant la fermeture du couvert entre 10 et 15 ans. Par la suite, deux à trois éclaircies sont effectuées entre 15 et 35 ans pour obtenir en fin de cycle une densité d'environ 300 arbres/ha [CRPFA, 2008]. Ces éclaircies successives entraînent une évolution de la structuration spatiale du couvert forestier qui se traduit dans les images satellite non seulement par des objets de dimensions de plus en plus grandes (diamètre de la couronne plus large), mais aussi par une disparition progressive de l'aspect aligné des peuplements. Cette évolution de la structuration spatiale de la forêt peut être exploitée pour cartographier l'âge des peuplements.

Il est néanmoins important de noter que cette évolution n'est pas à proprement parler figée. Ainsi, des variations de structure sont observées entre des peuplements de même âge en raison (1) de la variabilité des sites de production en termes de fertilité des sols, (2) des pratiques sylvicoles qui peuvent changer localement en fonction des stratégies employées par le gestionnaire ou (3) de perturbations naturelles. Cette dernière source de variations est particulièrement marquée dans la forêt des Landes. Cet écosystème a en effet connu récemment plusieurs épisodes de tempête, les derniers en date étant la tempête Klaus en février 2009 et la tempête Martin en décembre 1999. Les dégâts causés par la tempête Klaus ont été particulièrement importants avec 150 000 hectares de pins maritimes détruits à plus de 60% [IFN, 2009]. Les stigmates de ces dégâts sont actuellement toujours présents dans le paysage et la structuration spatiale de beaucoup de peuplements, en particulier les plus âgés, en est modifiée. Cela aura invariablement un impact sur la densité et la régularité spatiale des peuplements et donc sur l'homogénéité des textures à traiter.

### III.2.2 Site d'étude et données satellite

Le site d'étude est situé à proximité des communes de Marcheprime (44°41' N, 0°41' W) et d'Audenge (44°41' N, 1°01' W). Trois images ont été acquises sur cette zone par le satellite THR

Tableau 3.1 : Caractéristiques générales des images Pléiades et GeoEYE-1.

			Pléiades	GeoEYE-1
<b>Bande Panchromatique</b>	GSD (m)		0,7	0,41
	Résolution spatiale (m)		0,5	0,5
	Longueurs d'onde (nm)		470-910	450-800
<b>Bandes Multispectrales</b>	GSD (m)		2,8	1,65
	Résolution spatiale (m)		2	2
	Longueurs d'onde (nm)	Bleu	440-540	450-510
		Vert	500-600	510-580
		Rouge	610-710	655-690
		Proche Infrarouge	770-910	780-920

Tableau 3.2 : Métadonnées sur la géométrie d'acquisition des images Pléiades et GeoEYE-1.

	Pléiades 24/06/12	Pléiades 08/08/12	Pléiades 20/02/13	GeoEYE-1 03/04/13
Angle d'incidence	27,5°	15°	22°	20,5°
GSD PAN	0,83 m	0,74 m	0,78 m	0,45 m
Élévation solaire	66°	59,5°	32,5°	49°

Pléiades respectivement le 24/06/2012, le 08/08/12 et le 20/02/2013 dans le cadre de la Recette Thématique Utilisateurs (RTU) du programme ORFEO d'accompagnement Pléiades organisé par le CNES. Une quatrième image GeoEYE-1 a également été acquise le 03/04/2013 par la société Telespazio dans le cadre du projet EarthLab. L'emprise de ces quatre images est illustrée à la Figure 3.2. Ces images ont été fournies orthorectifiées avec les corrections géométriques d'usage. Les caractéristiques générales des images produites par ces deux capteurs sont résumées dans le Tableau 3.1. Les métadonnées relatives à la géométrie d'acquisition (angle d'incidence et élévation solaire) des quatre images exploitées sont quant à elles décrites dans le Tableau 3.2.

Les informations décrites dans le Tableau 3.1 suscitent quelques remarques. Tout d'abord, si la résolution spatiale (au sens de la taille des pixels dans l'image) est identique pour les deux capteurs, la distance d'échantillonnage au sol (au sens de la taille des pixels formés au niveau du capteur) ou *Ground Sample Distance* (GSD) diffère. Elle est ainsi plus précise dans le cas du capteur GeoEYE-1. Malgré le ré-échantillonnage à une résolution spatiale identique, le niveau de détail atteint par le capteur GeoEYE-1 est donc potentiellement plus fin que celui de Pléiades. On peut dès lors s'attendre à distinguer plus nettement les objets au sol dans cette image. Par ailleurs, l'étendue des longueurs d'onde utilisées pour définir la bande panchromatique (PAN) diffère également entre les deux capteurs. La bande PAN de GeoEYE-1 intègre uniquement une très faible partie du spectre correspondant au proche infrarouge. Ce domaine de longueur d'onde ayant un rôle prépondérant dans l'analyse de la végétation, il se peut que le contraste entre la végétation et le reste du paysage soit




Figure 3.3 : Histogrammes des images Pléiades du 24/06/2012 (gauche) et GeoEYE-1 du 03/04/13 (droite) après ré-étalement sur 8 bits.

moins marqué dans l'image GeoEYE-1 que dans l'image Pléiades. Cette remarque est importante dans notre contexte d'analyse texturale puisque cette analyse porte essentiellement sur la bande PAN.

Les métadonnées sur la géométrie d'acquisition des images (Tableau 3.2) indiquent plusieurs éléments qui auront un impact sur la qualité des images à traiter. L'angle d'incidence correspond à l'angle formé entre la visée du satellite et la verticale au sol. Plus cet angle est élevé, plus la GSD est dégradée et plus la capacité à distinguer dans l'image des objets de dimensions proches de la résolution spatiale se réduit. On peut remarquer que les quatre images ont été acquises avec un angle d'incidence élevé (supérieur ou égal à  $15^\circ$ ). La qualité de perception des textures dans ces images varie donc en fonction de cet angle et de la GSD du capteur. L'autre remarque concerne l'élévation solaire. Cette métadonnée indique l'angle entre l'horizontale au sol et la position du soleil. Plus cet angle est faible, plus les ombres portées au sol sont marquées dans l'image. Cela aura un impact sur la perception des textures et en particulier des textures en rang pour lesquelles les ombres portées modifieront le contraste entre le rang et l'inter-rang. Cet impact est fonction de l'orientation des rangs par rapport à la position du soleil. L'image Pléiades acquise en hiver (20/02/2013) est logiquement plus touchée par cet effet.

Une autre différence notable entre les images Pléiades et GeoEYE-1 relève de la dynamique radiométrique des images. En effet, les intensités de luminance dans les images Pléiades sont codées sur 12 bits (valeurs comprises entre 0 et 4095) alors que dans l'image GeoEYE-1, celles-ci sont codées sur 8 bits (valeurs comprises entre 0 et 255). La capacité à capter localement des différences radiométriques de faibles intensités est donc réduite dans l'image GeoEYE. Pour des soucis de facilité de manipulation des images Pléiades, la dynamique radiométrique a cependant été modifiée dans ces images en ré-étalant l'histogramme entre 0 et 255. Cette opération est réalisée en fixant les bornes de ré-étalement sur l'intervalle de l'histogramme dans lequel la dynamique principale se concentre. Ce faisant, les pixels de faibles intensités sont fixés à 0 et les pixels de fortes intensités sont saturés à 255. Cela n'affecte pas les zones de végétation peu concernées par ces effets de saturation et de faible réflectance. Un ré-étalement de l'histogramme est également effectué sur l'image GeoEYE afin de concentrer là aussi la dynamique autour de la partie de l'histogramme la plus dense. Malgré ce ré-étalement, la remarque formulée ci-dessus est toujours valable comme illustré à la Figure 3.3. Notons également que l'image GeoEYE est partiellement perturbée par l'ombre portée de nuages contribuant à la diminution de la dynamique radiométrique de cette image.




Figure 3.4 : Exemples de patches de texture représentatifs des quatre classes de forêt et issus de la base de données créée à partir de l'image Pléiades du 24/06/12.

### III.2.3 Bases de données de patches de texture

Des bases de données de patches de texture sont créées à partir de ces images satellite. Elles sont utilisées par la suite dans l'analyse d'indexation. Ces bases de données sont constituées en parcourant manuellement l'ensemble de l'image satellite panchromatique afin de repérer dans celle-ci toutes les zones de texture homogène représentatives des différentes classes d'âge de peuplement que l'on souhaite distinguer. De chacune de ces zones homogènes est alors extrait un patch de texture de dimension constante égale à  $256 \times 256$  pixels. Chaque patch est ensuite labellisé en déterminant sa classe par photo-interprétation en se basant sur le diamètre moyen des couronnes dans le peuplement visé.

Les classes considérées dans cette thématique correspondent à trois classes d'âge auxquelles s'ajoute une quatrième classe pour les coupe-rases. Des exemples de patches représentatifs de ces classes sont donnés à la Figure 3.4. Les caractéristiques des classes considérées sont les suivantes :

- La **classe d'âge 1** correspond aux peuplements les plus jeunes. Elle est caractérisée par la présence visible de rangs. Le couvert n'est pas fermé, le sol nu ou la végétation de sous-bois est visible à l'inter-rang. Le diamètre moyen des couronnes est inférieur à 1 m. Il faut noter que dans les peuplements les plus précoces d'âge inférieur à plus ou moins 3 ans, les jeunes pousses arbres sont de dimensions trop faibles pour être clairement perceptibles dans l'image. Néanmoins, des traces de labour résultant des travaux de nettoyage des parcelles avant le reboisement sont souvent annonciatrices d'une remise en culture. Les peuplements dans lesquels ces traces sont visibles ont été inclus dans cette classe.






Figure 3.5 : Localisation de la base de données de référence de classe d'âge de forêt. Les contours des 179 peuplements de référence sont indiqués en rouge.

- La **classe d'âge 2** inclut des peuplements d'âge intermédiaire avec un diamètre moyen des couronnes compris entre 1 et 3 m. Dans ces peuplements, les rangs de plantation sont toujours visibles, mais le couvert commence à se refermer et la végétation de sous-bois n'apparaît à l'inter-rang que dans les peuplements les plus jeunes.
- La **classe d'âge 3** inclut tous les peuplements les plus âgés dans lesquels les rangs sont plus rarement discernables. Le diamètre moyen des couronnes y est supérieur à 3 m. Des trouées peuvent apparaître dans les peuplements les plus âgés en raison soit d'opérations d'éclaircies, soit à la suite de perturbations naturelles (tempête, maladie, etc.). La densité des peuplements dans cette catégorie est ainsi plus variable que dans les deux précédentes.
- La classe des **coupe-rases** correspond aux parcelles récoltées et nettoyées. Aucun pin maritime n'y est visible, mais quelques espèces buissonnantes et autres feuillus peuvent persister. De la végétation rase est souvent présente dans ces parcelles.

Il est utile de signaler que la variable d'âge des peuplements est par définition une variable continue qui se prête difficilement à la discrétisation. Des chevauchements entre classes sont donc inévitables principalement à cause de la photo-interprétation et de la difficulté de catégoriser des peuplements proches de la limite entre deux classes. Cela aura nécessairement des répercussions sur la qualité de la discrimination obtenue à partir de ces bases de données.

Comme mentionné dans le chapitre I, les paramètres de texture dérivés des modèles multivariés sont par définition spécifiques à l'orientation principale des sous-bandes dont ils sont issus. Ils ne sont donc pas invariants par rotation. Afin de tester cette sensibilité, une seconde base de données de patches est



Figure 3.6 : Classes d'âge des peuplements de la base de données de référence.

crée pour chaque image satellite en opérant une rotation des patchs de texture anisotrope de telle sorte que leur orientation dominante soit forcée à  $0^\circ$ . Cette opération est réalisée après avoir estimé l'orientation dominante des patchs de texture par calcul du tenseur de structure. En pratique, l'orientation est estimée à partir du premier vecteur propre de la matrice de covariance des gradients. Le champ des gradients est quant à lui estimé sur les patchs par des filtres convolutifs Gaussiens à caractère dérivatif selon la direction considérée et lisse selon l'autre direction [Bigun *et al.*, 1991]. D'autres estimateurs d'orientation pourraient être utilisés pour cette étape [Le Pouliquen *et al.*, 2005 ; Michelet *et al.*, 2007]. Cette seconde base de données est exploitée lors de l'analyse d'indexation par CBIR. Les performances obtenues avec celle-ci sont comparées avec celles obtenues avec la première base de données afin d'analyser la sensibilité des différents modèles à l'orientation.

### III.2.4 Données de référence de classes d'âge

Au cours de l'année 2013, une base de données de référence de classes d'âge a été collectée auprès de l'Alliance Forêt-Bois sur le territoire de la municipalité d'Audenge par la société Telespazio (projet EarthLab). Cette base de données consiste en un fichier shapefile contenant les contours de 179 peuplements forestiers (Figure 3.5) avec leur classe d'âge correspondante s'étalant de 0 à 50 ans par tranche d'âge de 5 ans. Les coupe-rases sont également incluses dans la base de données. Les groupes d'âge ont été réarrangés en trois classes : une classe d'âge « 1 » contenant les jeunes peuplements de 1 à 9 ans, une classe d'âge « 2 » correspondant aux peuplements de 10 à 19 ans et une classe d'âge « 3 » regroupant les peuplements de 20 à 50 ans et plus. Une quatrième classe contient les coupe-rases (Figure 3.6).

Cette répartition des âges de peuplements se rapproche de celle employée pour classer la base de données de patchs de texture (paragraphe III.2.3). Néanmoins, elles ne sont pas équivalentes car elles



ne reposent pas sur les mêmes principes. La première est basée sur de la photo-interprétation et sur l'estimation dans l'image du diamètre moyen des couronnes avec tous les écueils et les biais classiques liés à la photo-interprétation. La seconde a été constituée par un recensement sur le terrain et le recueil de données sur l'âge des peuplements. Cette seconde base de données constitue de ce fait une véritable référence de terrain.

Ces données de référence d'âge des peuplements sont exploitées dans une analyse par validation croisée pour évaluer et comparer les performances de classification des différentes approches d'analyse de texture proposées (paragraphe III.4). En outre, une seconde base de données de référence est créée en opérant une rotation de chaque zone de l'image correspondant à un peuplement de texture anisotrope de telle sorte à modifier l'orientation dominante à 0°. Contrairement à la procédure utilisée pour les bases de données de patches, cette manipulation est réalisée ici manuellement. L'hétérogénéité de la texture au sein des régions rend effectivement l'estimation automatique de l'orientation moins fiable. Cette seconde base de données est également utilisée pour évaluer l'impact de l'orientation sur les descripteurs de texture, cette fois-ci dans un contexte de classification.

### III.3 Indexation par CBIR

Avant de présenter les résultats d'indexation, il est nécessaire de revenir sur la stratégie d'application des différentes approches d'analyse de texture. Dans le cas des matrices de co-occurrence, plusieurs paramètres doivent être fixés en tenant compte des caractéristiques des textures à différencier. Pour les modèles multivariés, des choix doivent être opérés sur le type de transformée en ondelettes utilisé.

#### III.3.1 Stratégie d'application des méthodes

##### III.3.1.1 Réglage des paramètres de la matrice de co-occurrence

Comme mentionné dans le chapitre I (paragraphe I.3.1.1 B), le choix des paramètres de la matrice de co-occurrence (GLCM) n'est pas automatisé et doit s'adapter au contexte. Deux paramètres doivent être ici déterminés : la distance entre paires de sites et le choix des descripteurs texturaux. La taille de la fenêtre d'analyse correspond à la dimension des patches de texture ( $256 \times 256$  pixels). Le nombre de niveaux de gris considéré dans le calcul des GLCMs est maintenu à 256. La stratégie adoptée consiste à tester différentes configurations de ces paramètres afin d'identifier une configuration optimale.

##### A. Sélection des descripteurs

Le premier problème abordé est celui de la sélection des descripteurs de GLCMs les plus pertinents. Pour ce faire, un ensemble de sept descripteurs est évalué : l'énergie, l'entropie, le contraste, la corrélation, l'homogénéité, la moyenne et la variance. Les cinq premiers ont été identifiés par [Maillard, 2003] comme les plus souvent utilisés dans la littérature. La moyenne et la variance des probabilités d'occurrence des paires de niveaux de gris font également partie des descripteurs couramment utilisés (par exemple [Kim *et al.*, 2009 ; Ruiz *et al.*, 2004 ; Warner & Steinmaus, 2005]). Ces sept descripteurs sont déterminés pour tous les patches de la base de données en fixant la distance à 2 pixels et en moyennant les paramètres sur 4 orientations. Une analyse en composantes principales (ACP) est ensuite réalisée sur ces descripteurs afin d'identifier ceux qui contribuent le plus aux premières composantes.

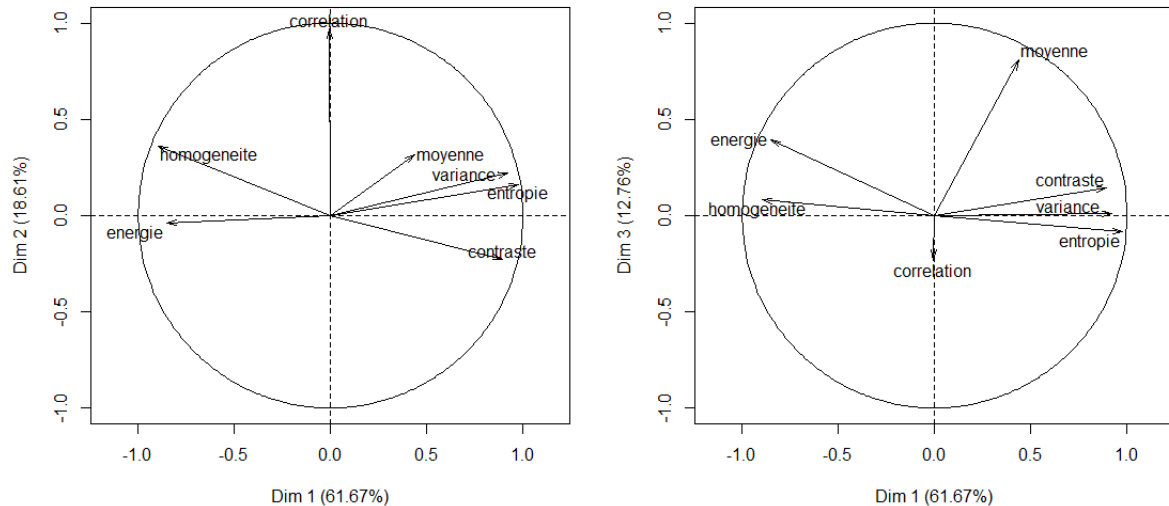


Figure 3.7 : Analyse en composantes principales sur les descripteurs de GLCM calculés à partir de la base de données issue de l'image Pléiades du 24/06/12. Les première et deuxième composantes sont représentées à gauche, les première et troisième à droite.

Les résultats de l'ACP pour les trois premières composantes sont présentés à la Figure 3.7. Ces résultats proviennent de l'analyse menée sur la base de données issue de l'image Pléiades du 24/06/2012. Les attributs de corrélation et de moyenne apparaissent nettement comme ceux qui contribuent respectivement le plus à la deuxième et à la troisième composante. Deux groupes d'attributs se distinguent dans l'analyse de la première composante avec d'un côté l'énergie et l'homogénéité et de l'autre la variance, l'entropie et le contraste. La sélection s'est opérée en considérant pour chacun de ces deux groupes l'attribut qui contribue le plus à la première composante, à savoir l'homogénéité et l'entropie. Les quatre descripteurs sélectionnés sont donc l'homogénéité et l'entropie pour la première composante, la corrélation pour la deuxième et la moyenne pour la troisième. Les mêmes descripteurs se sont révélés les plus pertinents dans l'analyse réalisée sur les trois autres images. Ces descripteurs sont également utilisés dans le cas des GLCMs sur ondelettes (WCFs).

### B. Sélection de la distance

Afin de sélectionner la distance la plus performante, un test d'indexation est mené en faisant varier la distance de déplacement entre 1 et 5 pixels en moyennant les descripteurs sur les quatre orientations (0, 45, 90, 135°). Les quatre descripteurs sélectionnés lors de l'étape précédente (homogénéité, entropie, corrélation et moyenne) sont utilisés dans ce test. Les résultats sont présentés à la Figure 3.8 pour les bases de données issues de l'image Pléiades du 24/06/2012 et du 20/02/2013.

Le meilleur taux de reconnaissance moyen (ARR) est obtenu avec une distance de 2 pixels. De manière générale, la distance entre paires de sites pour les GLCMs est souvent choisie en fonction de la taille des objets constitutifs du motif textural. Dans notre cas, la taille des objets n'est pas la même dans toute la base de données avec des arbres de petites dimensions dans les forêts les plus jeunes (1 à 2 pixels – 1 m) et des arbres de dimensions plus larges dans les forêts les plus âgées (jusqu'à 10 à 12 pixels – 5 à 6 m). La distance de 2 pixels est ici celle permettant de discriminer au mieux les différents motifs texturaux de la base de données quelque soit la taille des objets qui constituent ces motifs. Elle n'est donc pas ici le reflet de la taille des objets. Le même résultat a été obtenu pour les quatre images THR exploitées.






Figure 3.8 : Taux de reconnaissance moyens (ARR) obtenus avec la matrice de co-occurrence en fonction de la distance entre paires de site pour les bases de données issues de l'image Pléiades du 24/06/2012 (gauche) et du 20/02/13 (droite).

Dans le cas des GLCMs sur ondelettes (WCFs), la distance entre paires de sites est fixée à 1 pixel. En effet, l'image originale étant sous-échantillonnée d'un facteur 2 à chaque échelle de la décomposition, cette distance devrait être suffisante pour capturer les différences entre textures.

### III.3.1.2 Configuration de la transformée en ondelettes

Contrairement aux GLCMs, il ne s'agit pas ici de définir un ensemble de paramètres pour la méthode mais bien de faire le choix d'une stratégie générale d'application de la transformée en ondelettes et de prise en compte des dépendances à modéliser.

Tous les modèles considérés sont appliqués sur les sous-bandes issues d'une transformée en ondelettes discrète (DWT) avec une base d'ondelettes *Daubechies* 4 (db4). Même si elle est limitée en termes de sélectivité directionnelle et d'invariance à la translation (voir paragraphe I.3.2.3), la DWT présente l'avantage par rapport à d'autres transformations en ondelettes de fournir des sous-bandes indépendantes évitant ainsi la redondance d'information. Les filtres db4 sont quant à eux choisis pour le compromis qu'ils autorisent entre dispersion du filtre dans l'espace (plus sélectif dans le cas du filtre db2 par exemple) et localisation en fréquence (plus sélectif dans le cas du filtre db6 par exemple).

La transformée en ondelettes dyadique par DWT avec filtres db4 doit être appliquée selon un nombre d'échelles de décomposition à fixer. Comme remarqué dans [Do & Vetterli, 2002], la taille des sous-bandes doit être suffisante pour permettre d'estimer les paramètres des modèles. Les patches étant de dimension 256×256, à la quatrième échelle de décomposition, les sous-bandes auraient donc une taille de 16×16 ce qui pourrait s'avérer insuffisant pour estimer correctement les paramètres quelque soit le modèle utilisé. En réalité, cette remarque est également liée à la taille des voisinages considérés pour l'observation locale de la dépendance spatiale [Lasmar & Berthoumieu, 2014]. Si on considère un voisinage de dimension 4×4, la matrice de covariance résultante aura une dimension 16×16. On comprend aisément que l'estimation de cette matrice à partir d'une sous-bande de taille 16×16 est peu pertinente. Au vu de ces considérations, le nombre d'échelles a été fixé à 2 avec un voisinage spatial

de dimension  $3 \times 3$ . La décomposition ainsi configurée est appliquée sur tous les patches de la base de données produisant un total de six sous-bandes à modéliser ( $2 \text{ échelles} \times 3 \text{ orientations}$ ).

### III.3.2 Résultats d'indexation

Les classes des bases de données de patches de texture ne sont pas équilibrées en termes de nombre de patches par classe. La classe des coupe-rases est par exemple sous-représentée par rapport aux autres classes. Les résultats d'indexation pourraient donc être biaisés en étant plus fortement influencés par les classes les plus représentées. Pour remédier à cela, l'analyse d'indexation a été réalisée en procédant par une sélection aléatoire d'un nombre équivalent de patches par classe et en répétant cette procédure sur 100 itérations. A chaque itération, 25 patches sont sélectionnés aléatoirement pour chacune des quatre classes créant ainsi une nouvelle base de données de 100 patches. L'indexation est opérée sur ce sous-ensemble en récupérant les distances mesurées entre les patches sélectionnés lors de l'extraction des paramètres du modèle considéré. Un taux de reconnaissance ARR est ensuite déterminé en fonction de ces distances. A la fin des 100 itérations, un ARR moyen est calculé. Les courbes de Rappel/Précision sont quant à elles déterminées sur toute la base de données.

Cette opération est réalisée pour différentes méthodes d'analyse de texture :

- La matrice de co-occurrence en concaténant dans un même vecteur les descripteurs calculés dans les quatre orientations (GLCM),
- La matrice de co-occurrence en moyennant les descripteurs sur les quatre orientations garantissant une meilleure invariance à la rotation (GLCM\_INV),
- La matrice de co-occurrence calculée sur les sous-bandes d'ondelettes en moyennant les descripteurs sur les quatre orientations (WCF),
- Le modèle Gaussien multivarié (SCM),
- Le modèle SIRV Gaussien (SIRVgauss),
- Le modèle SIRV de distribution  $G0$  (SIRVg0),
- La Gamma multivariée sur copule Gaussienne (GCG) et
- La Gaussienne Généralisée Multivariée (MGG).

Les taux de reconnaissance ARR moyens obtenus pour toutes les méthodes d'analyse de la dépendance spatiale avec les bases de données originales (BD) et réorientées (BDrot) sont présentés à la Figure 3.9 pour les quatre images THR. Les courbes de Rappel/Précision associées aux modèles les plus performants sont quant à elles illustrées à la Figure 3.10 pour les bases de données BD et à la Figure 3.11 pour les bases de données BDrot.

Pour les bases de données BD, les résultats d'ARR montrent une nette supériorité des GLCMs par rapport aux modèles multivariés en termes de discrimination entre les classes d'âge de forêt considérées. Le fait de moyennner les descripteurs issus de ces GLCMs sur les quatre orientations (GLCM\_INV) permet d'atteindre des performances plus élevées indiquant l'intérêt du critère d'invariance à la rotation comme suggéré par [[Haralick et al., 1979](#)]. Pour ce qui est des modèles multivariés, les différences de performances varient d'une image à l'autre. Notons que de manière générale, la MGG affiche des performances plus faibles que les autres modèles hormis dans le cas de l'image GeoEYE. Comme observé par [[Verdoolaege et al., 2008](#)] dans des tests effectués avec ce modèle sur la base de données VisTex, la MGG est généralement plus performante en modélisation des dépendances couleur plutôt qu'en modélisation des dépendances spatiales. Cela peut expliquer les

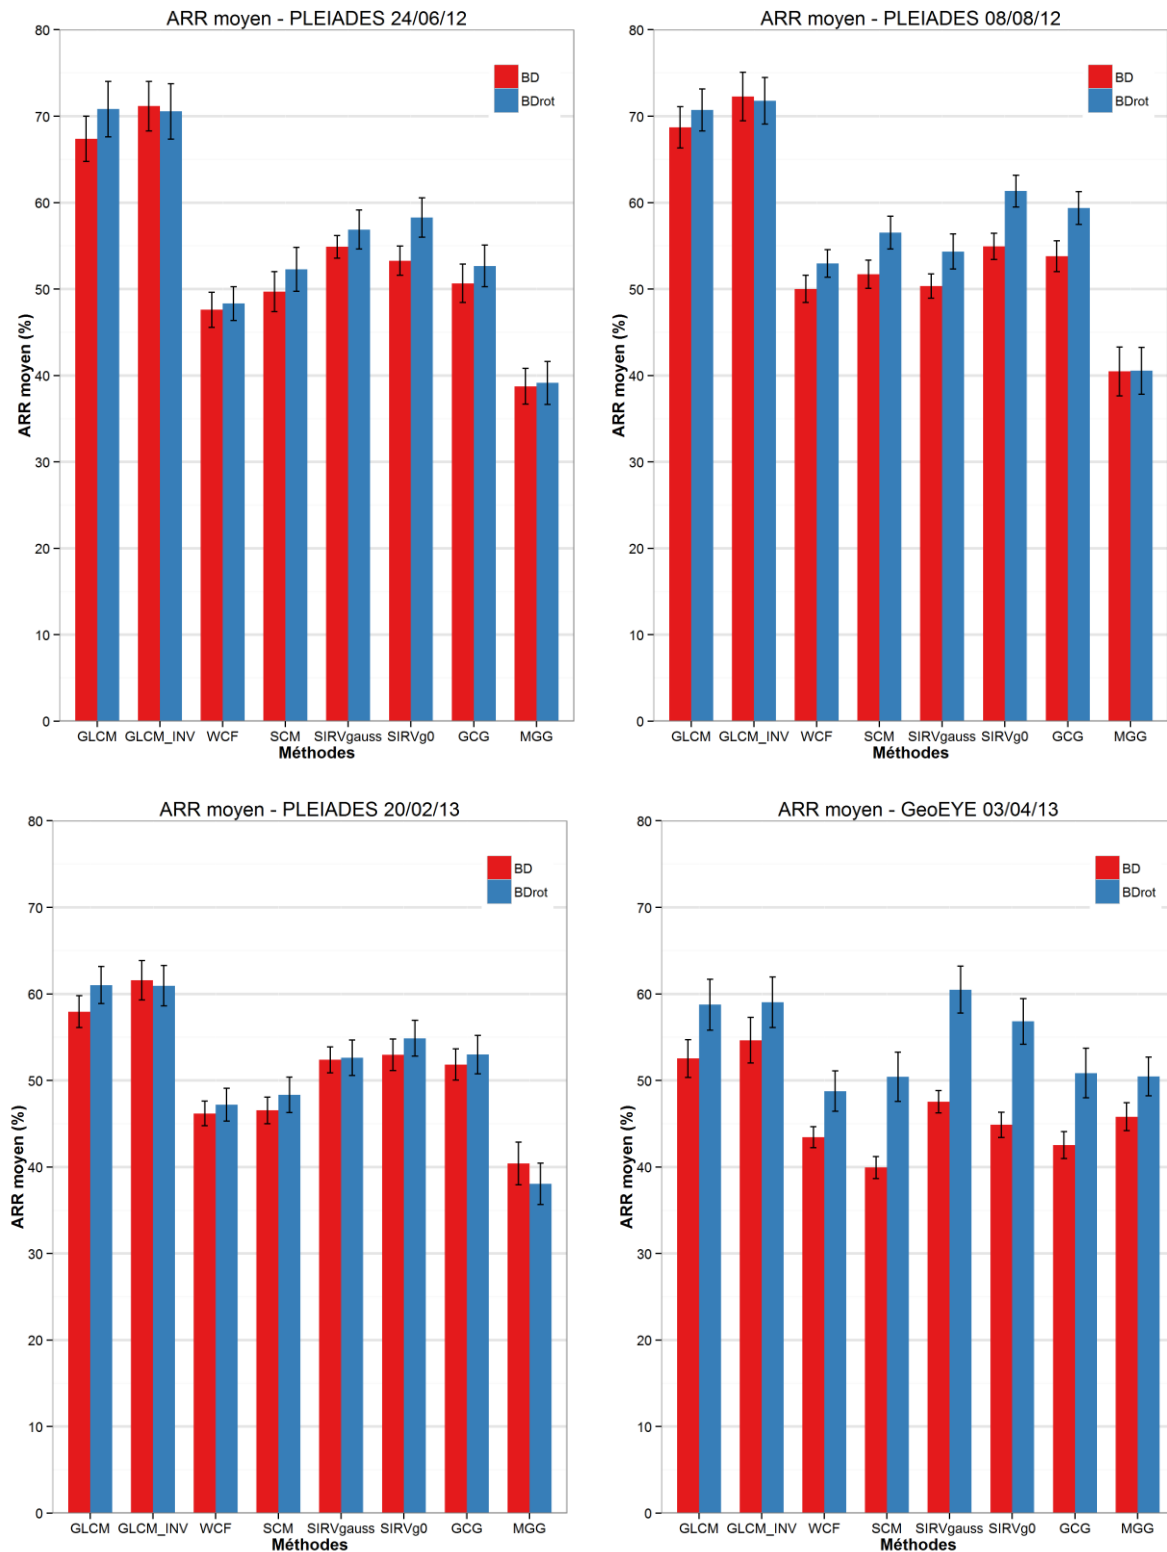


Figure 3.9 : Taux de reconnaissance moyens ARR obtenus par indexation sur les bases de données de patches de texture originales (BD - rouge) et réorientées (BDrot - bleu) des patches. Les barres d'erreur indiquent l'écart-type sur 100 itérations.

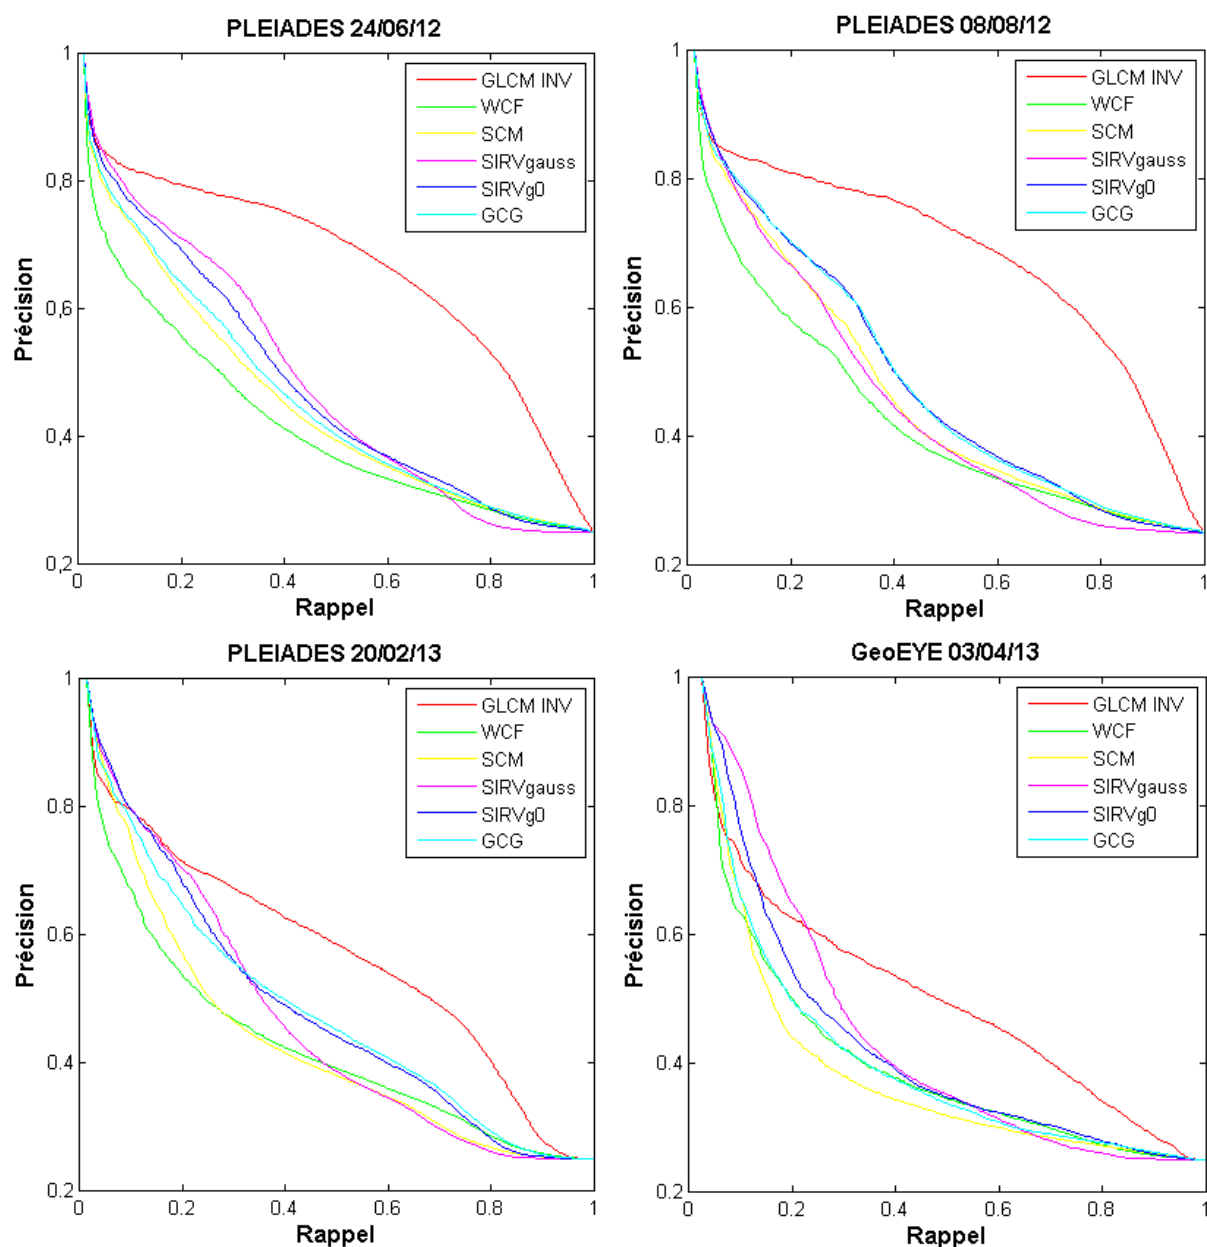


Figure 3.10 : Courbes de Rappel/Précision obtenues par indexation sur les bases de données de texture BD pour les quatre images satellite THR.

Tableau 3.3 : ARR (%) par classe pour l'image Pléiades 24/06/12.

	Classe d'âge 1	Classe d'âge 2	Classe d'âge 3	Coupe-rase
GLCM INV	60.4	64.5	79.9	60.2
SCM	23.0	38.5	66.7	15.5
SIRVgauss	21.9	31.0	80.8	15.7
SIRVg0	21.4	33.4	74.7	16.5
GCG	25.8	34.3	65.8	18.9

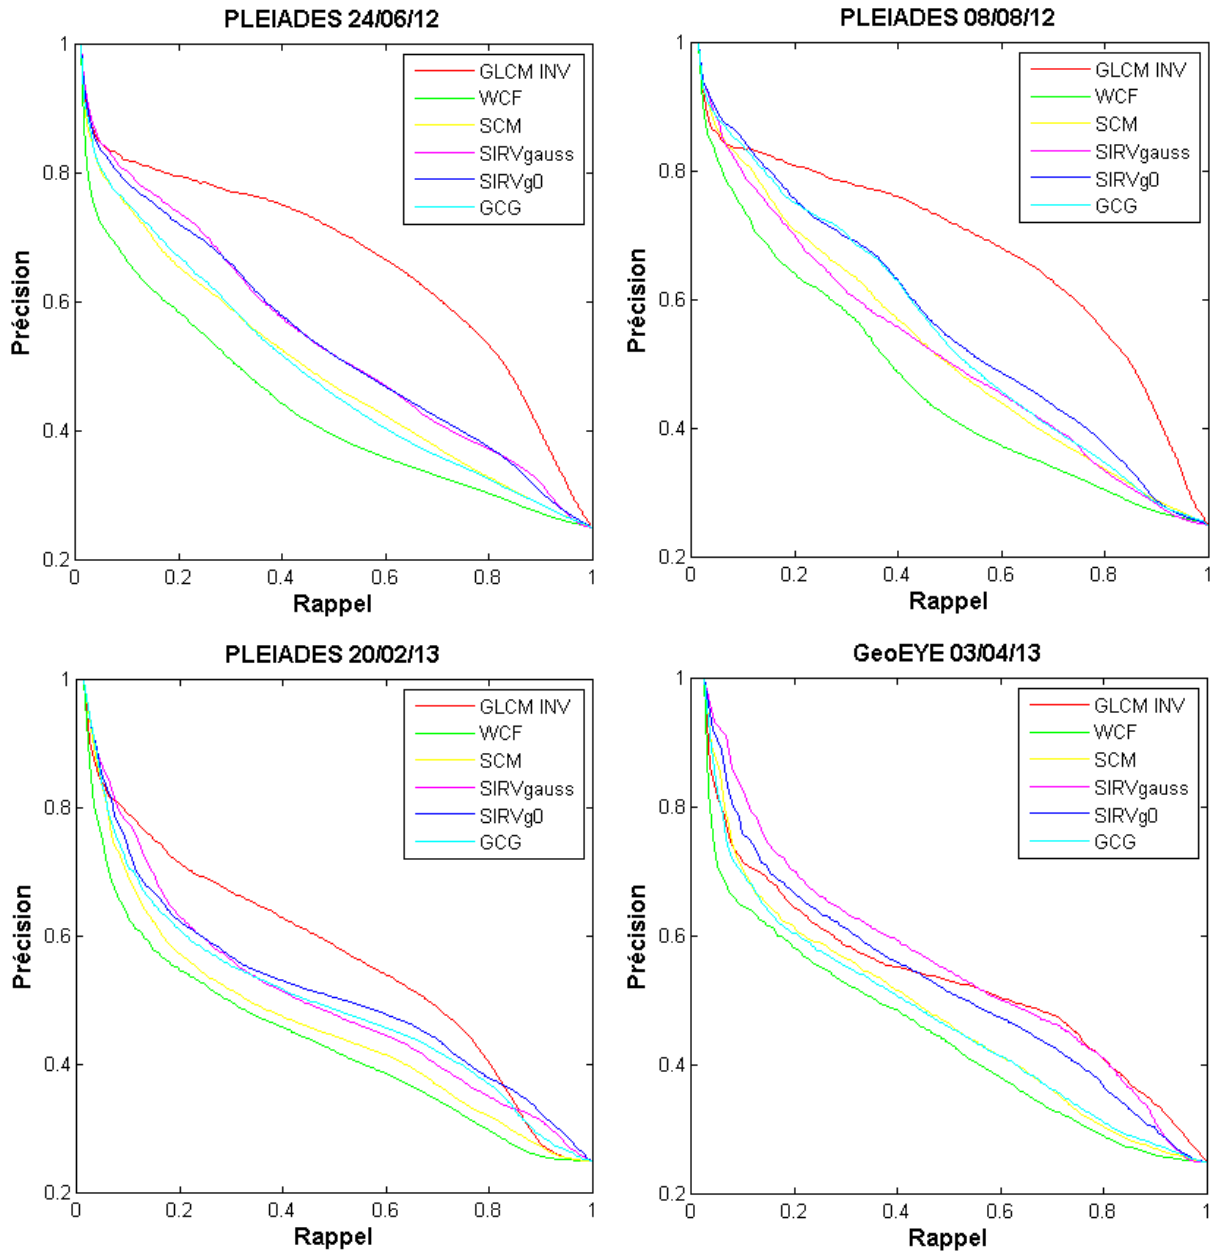


Figure 3.11 : Courbes de Rappel/Précision obtenues par indexation sur les bases de données de texture BDrot pour les quatre images satellite THR.

faibles performances de ce modèle. Pour le reste, les modèles WCF, SCM, SIRVgauss, SIRVg0 et GCG produisent des taux de reconnaissance statistiquement équivalents, sauf dans le cas des SCM et des WCFs moins performants sur les deux images d'hiver (Pléiades 20/02/13 et GeoEYE 03/04/13).

L'origine des différences de performances entre les GLCMs et les modèles multivariés pourrait provenir du manque d'invariance à la rotation de ces derniers. Les distances mesurées entre ceux-ci privilégieraient donc la détection de patches présentant non seulement le même motif mais aussi la même orientation que l'image requête. Cela se vérifie en observant les performances de détection par classe (Tableau 3.3). En effet, une différence apparaît dans la capacité des modèles multivariés à indexer correctement des images de textures anisotropes (principalement classes d'âge 1 et 2) par rapport aux GLCMs alors qu'ils se comportent bien dans l'indexation de textures plus déterministes (classe d'âge 3 par exemple). Cet effet dû au manque d'invariance à la rotation est visible dans les

résultats obtenus par indexation sur les bases de données présentant une seule orientation dominante à 0° (Figure 3.9 - BDrot). Les performances sur cette base de données sont en effet significativement supérieures pour la plupart des modèles par rapport à la base de données originale (BD), sauf dans le cas de l'image Pléiades 20/02/13. L'atténuation de l'effet lié à l'anisotropie permet donc d'améliorer la capacité de caractérisation des textures par les modèles multivariés. Les performances des GLCMs ne subissent pas de modifications significatives par ce changement. Elles n'en restent pas moins significativement supérieures aux modèles multivariés, sauf dans le cas de l'image GeoEYE.

Globalement, les ARR affichés par les différentes méthodes sont faibles avec des valeurs proches ou inférieures à 60% pour les GLCMs et proches ou inférieures à 50% pour les modèles multivariés et les WCFs. Rappelons ici que les différentes classes d'âge de peuplements à distinguer se chevauchent en raison de la discrétisation de la variable « âge du peuplement » qui par essence est continue. Les limites entre classes sont donc floues et des peuplements proches de ces limites entraînent invariablement des erreurs de classification. Ajoutons à cela la variabilité intrinsèque des classes (en particulier pour la classe d'âge 3) dans lesquelles des textures d'aspect très variable peuvent se côtoyer en raison des différences en termes de fertilité des sols, de pratiques culturales ou d'impacts de perturbations naturelles. De plus, l'ARR est un indice qui évalue les méthodes en les mettant dans le cas extrême où il faut détecter tous les individus d'une même classe à partir d'un seul représentant de cette classe. Au vu de la variabilité intra-classe affichée dans ce contexte, on comprend aisément les faibles performances affichées par l'ensemble des approches.

Ce que les ARR ne montrent pas, c'est si les individus d'une même classe correctement détectés sont plus ou moins proches de l'image requête. Cette information peut être appréhendée par l'analyse des courbes de Rappel/Précision. Suivre la courbe de Rappel/Précision depuis l'origine du graphique (coin supérieur gauche) équivaut à progressivement augmenter le seuil de distance entre l'image requête et les images de la base de données. On remarque que ces courbes décroissent rapidement depuis l'origine pour toutes les approches indiquant que lorsque le nombre d'images les plus proches considéré est faible, le nombre de bonnes détections est faible également. Cette tendance s'atténue toutefois progressivement, en particulier pour la GLCM. En effet, pour la base de données BD (Figure 3.10) et dans le cas des deux images d'été (Pléiades 24/06/12 et 08/08/12), la courbe de la GLCM se détache très tôt de celles des autres méthodes. Autrement dit, même en ne considérant que les quelques images les plus proches de l'image requête (seuil de distance bas), les GLCMs commettent moins d'erreurs de classification que les modèles multivariés. Par contre, dans le cas des deux images d'hiver (Pléiades 20/02/13 et GeoEYE 03/04/13), les modèles multivariés, en particulier les modèles basés sur les SIRVs, suivent la même tendance que la courbe de la GLCM pour de faibles seuils de distance. La courbe du modèle SIRVgauss dépasse même celle de la GLCM dans le cas de l'image GeoEYE. Cela signifie que ces modèles placent autant ou plus d'images de la même classe que l'image requête dans les premières images les plus proches que les GLCMs. L'utilisation de ces modèles dans un classifieur de type  $k$ -NN basé sur la notion de distance en choisissant un  $k$  faible donnerait donc de meilleurs résultats que l'utilisation des GLCMs.

Les mêmes courbes de Rappel/Précision obtenues avec la base de données BDrot (Figure 3.11) confirment l'amélioration des performances des modèles multivariés en compensant l'effet lié à l'anisotropie. Hormis pour l'image Pléiades du 24/06/12, la courbe des modèles multivariés suit voire dépasse celle des GLCMs principalement lorsque l'on considère un seuil de distance faible. C'est particulièrement le cas pour les modèles basés sur les SIRVs.

Il est délicat de proposer des hypothèses pour expliquer les différences de performances observées entre les différentes images satellite tant les sources de variations sont nombreuses. On peut toutefois remarquer que les modèles multivariés semblent mieux fonctionner sur les images d'hiver (Pléiades 20/02/13 et GeoEYE 03/04/13). En cette saison, la végétation de sous-bois est généralement moins développée et le contraste entre les rangs de plantation et l'inter-rang est plus marqué dans ces images. Ce facteur pourrait être plus bénéfique aux modèles multivariés qu'aux GLCMs.

En conclusion de cette analyse, on peut noter que dans un contexte d'indexation, les GLCMs affichent de meilleures performances que les modèles multivariés en particulier lorsque les descripteurs sont moyennés sur les orientations. Par ailleurs, les modèles multivariés semblent être plus sensibles à l'anisotropie des textures et le fait d'atténuer cette anisotropie permet d'améliorer leurs performances [Regniers *et al.*, 2013]. Dans les cas impliquant un seuil de distance faible, les modèles multivariés afficheraient de meilleurs résultats que les GLCMs. Ce serait par exemple le cas en utilisant un classifieur de type  $k$ -NN avec un  $k$  de faible valeur. Parmi les modèles multivariés, les modèles SIRVs et dans une moindre mesure les modèles SCM et GCG indiquent des performances équivalentes. Dans la partie suivante, ces quatre modèles sont évalués et comparés aux GLCMs dans un contexte de classification.

### III.4 Résultats de classification

Dans cette partie, les modèles multivariés identifiés dans l'analyse par indexation sont évalués et comparés aux GLCMs dans un contexte de classification en se basant sur une donnée de référence d'âges des peuplements acquise auprès de l'Alliance Forêt-Bois sur la commune d'Audenge (voir paragraphe III.2.4). Comme détaillé dans le paragraphe II.3.2.1, cette analyse est réalisée au travers d'une procédure par validation croisée en séparant la base de données à chaque itération en données d'apprentissage et données de validation. Contrairement à l'analyse par indexation, les paramètres décrivant les dépendances sont ici extraits à partir de tous les pixels du peuplement et non à partir d'un patch de texture homogène issu de celui-ci [Regniers *et al.*, 2014b ; Regniers *et al.*, 2014c].

Plusieurs modalités de caractérisation des peuplements sont proposées dans cette analyse :

- A partir de l'image panchromatique, une analyse de la dépendance spatiale (**SP**) focalisée uniquement sur la texture est réalisée sur chaque peuplement en extrayant les paramètres de texture dérivés des GLCMs ainsi que des quatre modèles multivariés identifiés (SCM, SIRVgauss, SIRVg0 et GCG).
- La seconde modalité s'appuie sur des paramètres décrivant la dépendance couleur (**COL**) utilisant les mêmes modèles multivariés à partir des quatre bandes spectrales de l'image multispectrale.
- Dans une troisième modalité, les paramètres de dépendance spatiale et de dépendance couleur sont combinés dans un même vecteur (**SP+COL**).
- La quatrième modalité reprend l'analyse des dépendances spatiales mais en estimant les modèles sur les mêmes peuplements ayant fait l'objet d'une rotation (**SProt**). Cette modalité permettra d'évaluer l'impact de l'anisotropie sur les différents modèles et sur les GLCMs.

- Enfin, dans la dernière modalité, ces paramètres de dépendance spatiale sont à nouveau combinés aux paramètres de dépendance couleur (**SProt+COL**).

L'analyse de la dépendance couleur n'étant pas applicable dans le cas des GLCMs, seules les modalités **SP** et **SProt** sont appliqués pour cette approche. Les résultats sont présentés dans les parties suivantes pour deux classifieurs : les  $k$ -NN et les SVMs.

### III.4.1 Résultats obtenus par $k$ -NN

Pour ce classifieur, il est nécessaire de fixer au préalable la valeur du paramètre  $k$ . La base de données étant déséquilibrée en termes de nombre de peuplements par classe, le paramètre  $k$  est fixé en fonction du nombre d'individus dans la classe la moins représentée. Il s'agit ici de la classe des coupe-rases qui ne contient que 15 individus. Cette classe étant divisée en deux à chaque itération de la validation croisée (7 peuplements pour l'apprentissage et 8 pour la validation), une valeur de 5 est choisie pour ce paramètre.

Les résultats de précision globale de classification (*Overall Accuracy*) obtenus pour l'ensemble des méthodes et pour chaque modalité testée sont présentés à la Figure 3.12. La modélisation de la dépendance spatiale (SP) est la plus performante lorsqu'elle est réalisée au moyen des modèles SIRVs et en particulier du modèle SIRVgauss. De manière générale, les modèles multivariés affichent de meilleures performances de classification que les GLCMs à l'exception de l'analyse menée sur l'image Pléiades du 24/06/12. Ces résultats contrastent avec ceux présentés dans l'analyse par indexation, mais confirment toutefois les observations réalisées lors de cette analyse sur la capacité des modèles multivariés SIRVs à bien se comporter lorsqu'un seuil de distance faible est considéré entre l'individu à classer et les peuplements d'apprentissage. C'est effectivement le cas lors de cette classification par  $k$ -NN avec un  $k$  égal à 5. Néanmoins, les différences entre modèles SIRVs et GLCM observées en indexation étaient faibles et témoignaient au mieux d'une légère supériorité des modèles SIRVs dans le cas de l'image GeoEYE. Ici, ces modèles multivariés surpassent nettement les performances des GLCMs pour trois des quatre images satellite analysées. Une explication possible de cette supériorité réside dans le fait que nous ne sommes plus dans un contexte de comparaison entre patchs d'image illustrant des textures homogènes, mais bien dans une comparaison entre peuplements entiers homogènes en termes d'âge mais plus nécessairement en termes de texture en raison de la variabilité interne existant au sein de ces peuplements. Les modèles multivariés semblent être plus robustes face à cette plus grande complexité de l'information texturale que les GLCMs.

Par ailleurs, lorsque l'orientation principale des peuplements est ramenée à  $0^\circ$  dans la modalité SProt, les performances atteintes par les GLCMs sont améliorées significativement et leur niveau de précision de classification devient alors équivalent au meilleur des modèles multivariés. A l'inverse, les performances des modèles multivariés ne sont pas ou peu affectées par cette modification. On se retrouve ici à nouveau face à des observations contradictoires par rapport aux résultats d'indexation. Pour mieux percevoir les nuances dans cette comparaison, les performances par classe sont analysées (Tableau 3.4 et 3.5).

Dans le cas du modèle SIRVgauss (Tableau 3.4), la classe d'âge 3 est la mieux détectée par la modélisation de la dépendance spatiale (SP) avec une précision du producteur (PA) de près de 95%. Les confusions sont plus fréquentes pour les classes d'âge 1 et 2 probablement parce qu'elles sont associées toutes les deux à des textures anisotropes. Néanmoins, lorsque les orientations sont forcées à






Figure 3.12 : Précision globale moyenne (Overall Accuracy) par validation croisée avec un classifieur  $k$ -NN ( $k = 5$ ). SP = dépendance spatiale, COL = dépendance couleur, SP+COL = dépendances spatiale et couleur, SProt = dépendance spatiale avec rotation, SProt+COL = dépendances spatiale et couleur après rotation. Les barres d'erreur indiquent l'écart-type sur 100 itérations.

Tableau 3.4 : Précisions de classification par classe (%) pour le modèle SIRVgauss sur l'image Pléiades du 08/08/12 avec classifieur  $k$ -NN.

		Classe d'âge 1	Classe d'âge 2	Classe d'âge 3	Coupe- Rase	OA	Kappa
SP	PA	73.24	63.86	94.55	56.62	73.47	0.63
	UA	90.99	71.6	63.07	67.53		
COL	PA	66.06	73.69	81.3	32.5	68.89	0.56
	UA	78.46	65.73	65.73	63.73		
SP+	PA	72.47	79.66	86	47.87	75.57	0.65
	COL	87.64	70.52	70.52	67.26		
SProt	PA	83.09	69	82.1	47.37	75.24	0.65
	UA	88.82	73.24	73.24	80.12		
SProt+	PA	86.91	79.62	85.35	50.75	<b>81.07</b>	<b>0.76</b>
	COL	89.27	76.63	76.63	93.49		

OA = Overall Accuracy – PA = Producer's Accuracy – UA = User's Accuracy

Tableau 3.5 : Précisions de classification par classe (%) pour la GLCM sur l'image Pléiades du 08/08/12 avec classifieur  $k$ -NN.







		Classe d'âge 1	Classe d'âge 2	Classe d'âge 3	Coupe- Rase	OA	Kappa
SP	PA	70.26	61.21	65.85	60.62	64.35	0.57
	UA	77.62	55.85	60.16	73.17		
SProt	PA	82.94	72.31	75	54.62	<b>75.32</b>	<b>0.65</b>
	UA	85.62	72.17	68.94	71.03		

OA = Overall Accuracy – PA = Producer's Accuracy – UA = User's Accuracy

0° (SProt), les PAs de ces deux classes sont significativement augmentées (près de 10 % pour la classe d'âge 1) indiquant effectivement que l'anisotropie pourrait être une source de confusion. L'*Overall Accuracy* (OA) pour cette modalité n'est pourtant pas plus élevée car cette amélioration est neutralisée par une diminution des PAs pour la classe d'âge 3 et les coupe-rases. Ceci indique au contraire que l'anisotropie peut être une source de discrimination importante entre la classe d'âge 3 et les autres classes d'âge. En ce qui concerne les résultats des GLCMs (Tableau 3.5), les améliorations observées entre SP et SProt sont significatives pour toutes les classes sauf pour les coupe-rases. Cela montre que dans ce cas, la discrimination entre texture isotrope et anisotrope est meilleure lorsque l'orientation des textures est homogène alors que les descripteurs des GLCMs sont supposés être invariants à la rotation. Ces quelques observations semblent démontrer que les GLCMs sont plus efficaces que les modèles multivariés dans la représentation des textures homogènes quelle que soit leur orientation. À l'inverse, lorsque la complexité de l'information texturale s'accroît, les modèles multivariés sont susceptibles de mieux capturer cette complexité que les GLCMs pour lesquelles le facteur d'orientation peut devenir une source de confusion.

L'ajout d'attributs de la dépendance couleur à la dépendance spatiale (SP+COL) n'améliore pas ou peu les performances de classification des modèles sur sous-bandes d'ondelettes. L'analyse par classe pour le modèle SIRVgauss (Tableau 3.4) montre cependant une augmentation de la PA pour la classe d'âge 2 neutralisée par une diminution pour les classes d'âge 1 et 3. La couleur peut en effet contribuer à une diminution des confusions entre les deux classes les plus jeunes. La réponse spectrale de la classe d'âge 1 est probablement influencée par une fraction de sol nu plus élevée en raison

Tableau 3.6 : Exemples de peuplements aberrants.

 <p>A</p> <p>Peuplement de classe d'âge 1 partageant des caractéristiques avec les peuplements les plus âgés de classe 3 en raison de la présence d'arbres feuillus ou d'arbustes.</p>	 <p>B</p> <p>Coupe-rase ressemblant à un peuplement jeune de classe d'âge 1.</p>
 <p>C</p> <p>Peuplement de classe d'âge 2 récemment éclairci et partageant des aspects communs avec des peuplements de classe d'âge 3.</p>	 <p>D</p> <p>Peuplement de classe d'âge 2 ayant subi des dégâts de tempête.</p>
 <p>E</p> <p>Peuplement de classe d'âge 2 avec une densité de plantation hétérogène.</p>	 <p>F</p> <p>Opérations de nettoyage en cours sur une coupe-rase.</p>

d'opérations de nettoyage avant la reforestation et par une fraction de biomasse verte plus faible. Inversement, les forêts denses de la classe d'âge 3 partagent des traits communs en termes de réponse spectrale avec les forêts les plus âgées de la classe 2 et de plus grandes confusions peuvent se produire.

Pour les deux images d'été, la combinaison entre dépendance couleur et l'homogénéisation du facteur orientation (SProt+COL) révèle un effet synergétique pour tous les modèles multivariés à l'exception notable du modèle SIRVg0. Cette modalité affiche les meilleures performances et une amélioration pour toutes les classes d'âge dans le cas du modèle SIRVgauss. La diminution de la PA pour la classe d'âge 3 observée dans la modalité SProt est ici atténuée par l'ajout de la dépendance couleur.

Il faut signaler également que les performances obtenues sont probablement surestimées en raison de l'effet dû à la proximité directe des peuplements à classer. Les peuplements voisins ont en effet une probabilité plus grande de partager certaines caractéristiques telles que l'orientation des rangs, les pratiques culturales, etc. Cela entraîne potentiellement une augmentation artificielle des performances. Mais, même si les précisions de classification absolues sont à considérer avec précautions, les conclusions tirées des performances relatives entre les différents modèles restent valables.

Malgré l'ajout de la dépendance couleur et la compensation de l'effet lié à la variabilité des orientations, les modèles proposés peinent néanmoins à dépasser les 80% de bonnes classifications. Afin de mieux comprendre ces erreurs de classification observées, il est nécessaire de signaler qu'une partie non-négligeable de la base de données de référence (approximativement 15%) est composée de peuplements d'aspect aberrant. Ces peuplements ne sont pas aberrants par l'âge qui leur est associé, mais parce qu'ils présentent un aspect texturé qui les rend différents de l'aspect visuel général de la classe à laquelle ils appartiennent. C'est par exemple le cas de certains peuplements les plus jeunes dans lesquelles quelques feuillus et autres arbustes isolés peuvent persister leur donnant un aspect comparable aux peuplements de classes d'âge 3 les moins denses (Tableau 3.6 A). Des marques laissées au sol par les opérations de nettoyage dans certaines coupe-rases peuvent aussi induire des confusions avec les peuplements de classe d'âge 1 les plus jeunes (Tableau 3.6 B). D'autres sources de divergence peuvent provenir d'autres phénomènes locaux. Ainsi, dans les peuplements de plus de 10 ans (classes d'âge 2 et 3), des opérations d'éclaircies récentes provoquent des changements dans la densité des forêts et dans la croissance des couronnes ce qui altère le motif textural (Tableau 3.6 C). Des résidus de dégâts de tempête causent aussi des changements locaux de densité. Des forêts endommagées d'âge moyen (classe d'âge 2) peuvent partager des caractéristiques communes avec des forêts plus âgées en raison de la présence de clairières (Tableau 3.6 D). La densité de plantation peut également varier d'un gestionnaire forestier à l'autre avec des divergences d'aspect dans les forêts les plus jeunes (Tableau 3.6 E). Enfin, des pratiques culturales différentes peuvent coexister au sein d'un même peuplement ou encore, la donnée satellite peut être acquise pendant une opération de nettoyage. Des motifs texturaux différents sont alors observables dans un seul peuplement (Tableau 3.6 F). Tous ces phénomènes illustrent les limites de l'*a priori* principal de cette étude qui est de considérer que la relation entre l'âge des peuplements et la distribution spatiale des arbres est simple. On constate que dans la réalité, ce n'est pas toujours le cas. Mais, cela signifie aussi que des performances proches de 85% sont satisfaisantes dans les limites des approches utilisées. Les erreurs de classification proviennent ainsi essentiellement de divergences entre l'aspect texturé des peuplements et leur âge et non d'erreurs de modélisation des textures par les approches proposées.

Tableau 3.7 : Précisions de classification par classe (%) pour le modèle SIRVgauss sur l'image Pléiades du 08/08/12 avec classifieur SVM.

		Classe d'âge 1	Classe d'âge 2	Classe d'âge 3	Coupe- Rase	OA	Kappa
SP	PA	91.68	78.76	85	40	81.55	0.73
	UA	84.23	80.6	80.3	81.9		
COL	PA	94.53	75	71.1	7.37	75.5	0.64
	UA	71.26	76.18	83.37	54		
SP+	PA	93.47	84.65	84.25	39.37	83.89	0.77
	COL	86.03	81.2	84.13	98.1		
SProt	PA	91.91	79.17	67.15	34.62	77.37	0.67
	UA	81.93	73.24	76.8	86.56		
SProt+	PA	94.18	84.1	84.4	39.62	84.02	0.77
	COL	85.9	71.59	84.37	94.8		

OA = Overall Accuracy – PA = Producer's Accuracy – UA = User's Accuracy

Rappelons également ici le fait que les limites entre classes d'âge ont été fixées de manière arbitraire sur une variable qui par essence est continue. Un peuplement d'âge proche de la limite entre deux classes sera invariablement associé à des difficultés de classification.

Notons également que les meilleures performances des modèles multivariés sont atteintes sur l'image Pléiades du 08/08/12 en ajoutant la dépendance couleur. Cette même dépendance couleur semble être moins bénéfique dans le cas des images d'hiver pour lesquelles une plus grande hétérogénéité des réponses spectrales est observable dans les peuplements en raison du moindre développement de la végétation rase de sous-bois en cette saison. De plus, l'élévation solaire plus faible pour ces images entraîne une élongation des ombres portées qui contribuent à l'atténuation des réponses spectrales à l'inter-rang. Par ailleurs, l'intérêt potentiel de la distance d'échantillonnage plus fine dans l'image GeoEYE (0,45 m au lieu des 0,7 à 0,8 m pour les images Pléiades) n'apparaît pas dans les résultats. Comme signalé dans la partie III.2.2, ceci peut être dû à l'ennuagement partiel de cette image, à sa plus faible dynamique radiométrique ou à l'intégration plus restreinte du rayonnement infrarouge dans la bande panchromatique. Malgré ces remarques, il reste délicat de tirer des conclusions sur les avantages ou les inconvénients du type de capteur utilisé ou de la saison d'acquisition des images.

### III.4.2 Résultats obtenus par SVM

Le classifieur SVM est testé sur la même base de données et selon les mêmes modalités que le classifieur  $k$ -NN. Le seul paramètre à fixer lors de cette analyse est le paramètre  $\sigma$  déterminant la taille du noyau Gaussien  $K = \exp(-(distance)^2/\sigma^2)$  appliqué lors de la transformation non-linéaire de l'espace des paramètres (paragraphe II.3.2.3). Celui-ci est fixé au cas par cas par essai-erreur. Le  $\sigma$  qui maximise les performances est conservé. Notons qu'il est égal à 1 pour tous les modèles lors de l'analyse des dépendances spatiale et couleur prises individuellement. Il monte à des valeurs comprises entre 2 et 4 lorsque ces deux dépendances sont combinées.

Les précisions globales (OA) obtenues avec le classifieur SVM sont présentées à la Figure 3.13. Dans la grande majorité des cas, on peut remarquer que ce classifieur permet d'atteindre des performances de classification plus élevées qu'avec le classifieur  $k$ -NN. Tous les modèles et tous les types de

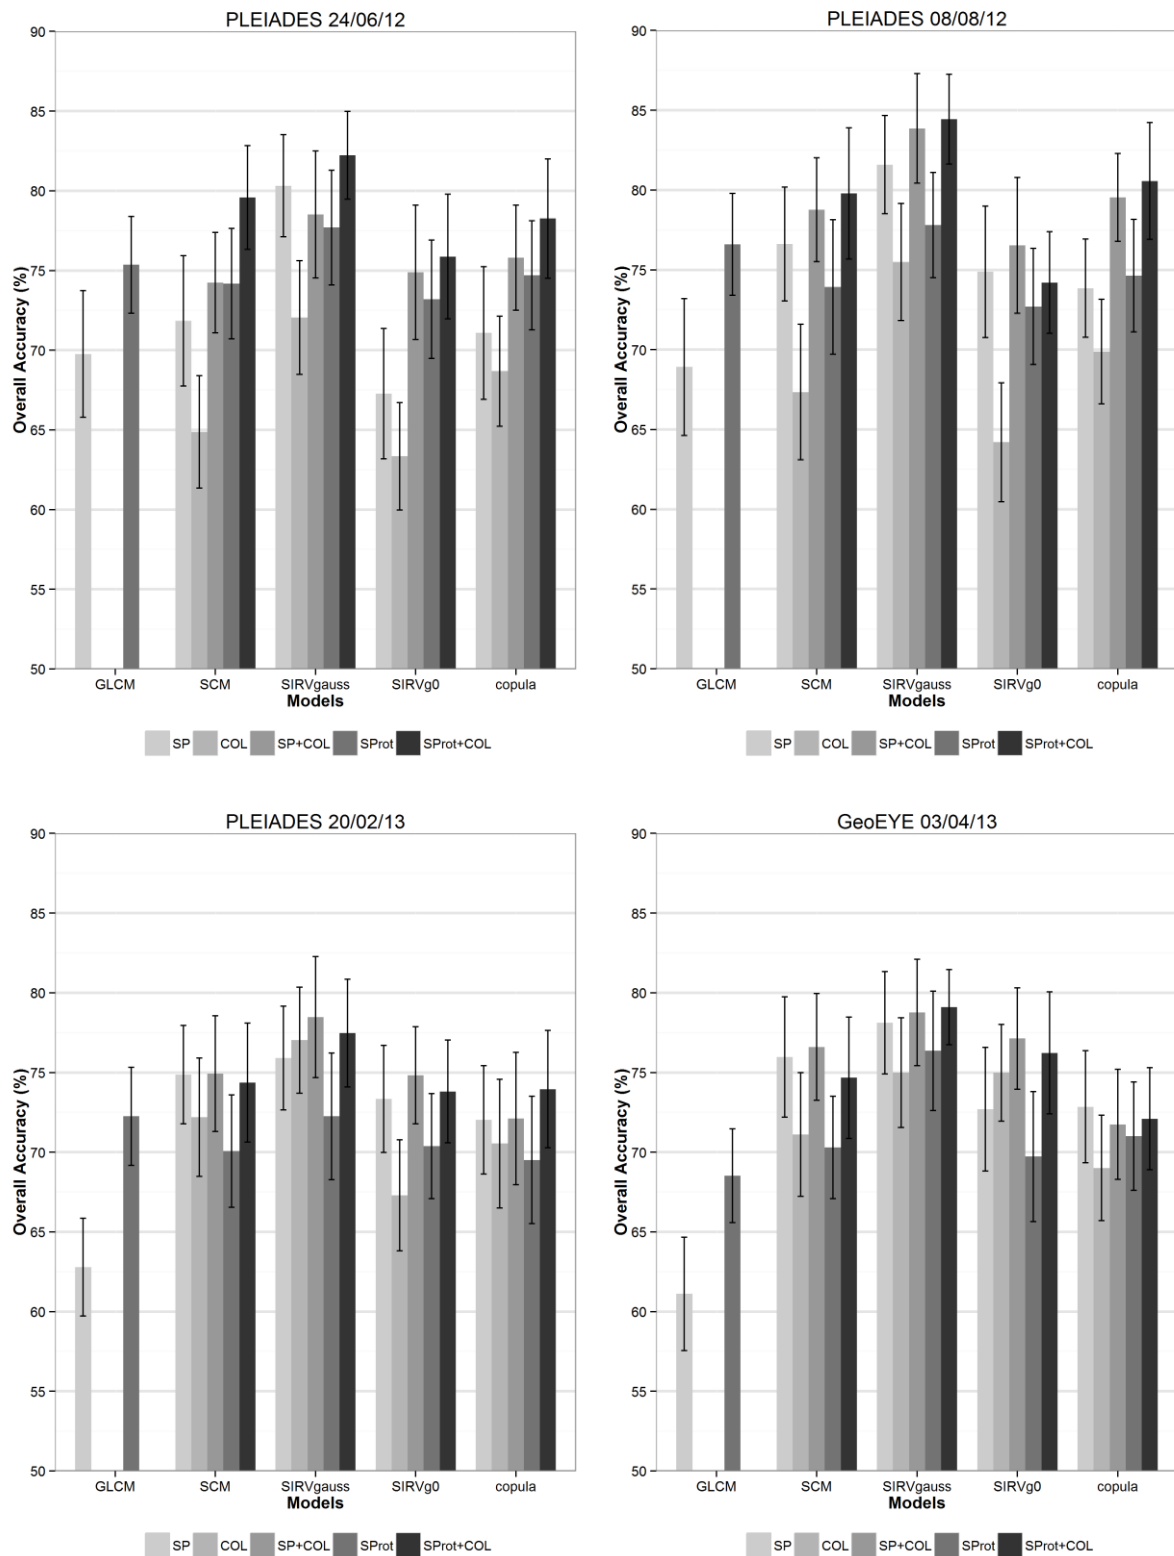


Figure 3.13 : Précision globale moyenne (Overall Accuracy) par validation croisée avec classifieur SVM. SP = dépendance spatiale, COL = dépendance couleur, SP+COL = dépendances spatiale et couleur, SProt = dépendance spatiale avec rotation, SProt+COL = dépendances spatiale et couleur après rotation. Les barres d'erreur indiquent l'écart-type sur 100 itérations.

modalités sont concernés. Toutefois, les performances relatives des différentes approches ne sont pas globalement modifiées et le modèle SIRVgauss reste le plus performant des modèles multivariés. Notons aussi que l'augmentation des performances est généralement plus faible pour les GLCMs. Ces résultats confirment l'intérêt des SVMs et leur capacité à limiter les erreurs de classification.

L'analyse des performances par classe pour le modèle SIRVgauss (Tableau 3.7) permet de mieux comprendre là où les SVMs sont plus efficaces que le classifieur par  $k$ -NN (Tableau 3.4). Ainsi, lors de l'analyse de la dépendance spatiale (SP), les SVMs permettent de mieux discriminer les classes d'âge 1 et 2 que les  $k$ -NN. La source principale de confusion entre ces deux classes étant potentiellement leur anisotropie, il semble donc que les SVMs soient plus à même de gérer la variabilité des orientations dans le processus de classification. Cela s'accompagne toutefois d'une moindre PA sur la classe d'âge 3. Les paramètres de la dépendance couleur (COL) paraissent également mieux représentés dans l'espace transformé des SVMs pour les deux classes d'âge les plus jeunes ce qui se traduit logiquement par une meilleure discrimination des classes d'âge 1 et 2 dans la modalité SP+COL. La confusion liée à l'anisotropie est atténuée avec l'emploi des SVMs et finalement, le fait de retourner tous les peuplements à 0° n'apporte plus vraiment d'améliorations. Ce constat vaut pour la majorité des modèles et pour toutes les images satellite hormis pour l'image du 24/06/12.

On remarque également que comme dans le cas des  $k$ -NN, le plafond des 85% de bonnes classifications est difficilement dépassé par les SVMs. Cela confirme l'impact non-négligeable des peuplements aberrants sur les résultats.

## III.5 Conclusions et perspectives

### III.5.1 Conclusions

Dans ce chapitre, nous avons évalué l'intérêt des modèles multivariés de texture sur sous-bandes d'ondelettes dans un contexte de classification d'âges de peuplements forestiers issus d'une forêt mono-spécifique cultivée de pins maritimes. Les performances de caractérisation de la texture de ces modèles ont été comparées avec celles obtenues par les matrices de co-occurrence dans le cadre de deux analyses : l'indexation d'images à partir d'une base de données de patches de textures homogènes et la classification de peuplements à partir d'une base de données de référence de classes d'âge. Plusieurs conclusions peuvent être tirées des résultats présentés.

Dans l'analyse d'indexation de patches de textures homogènes, les attributs dérivés des GLCMs se sont révélés plus performants que les modèles multivariés testés principalement en raison de l'invariance à la rotation de ces attributs. La présence de textures anisotropes (classes d'âge 1 et 2) dans la base de données semble être une source de confusion importante pour les modèles multivariés. Néanmoins, lorsque l'information texturale se complexifie comme c'est le cas dans l'analyse par classification de peuplements forestiers, les modèles multivariés sur sous-bandes d'ondelettes ont démontré une plus grande efficacité de discrimination entre les classes d'âge de forêt malgré l'hétérogénéité plus marquée des textures à classer. Parmi les modèles multivariés, l'utilisation des modèles basés sur les SIRVs et en particulier le modèle SIRVgauss s'est avéré être la stratégie la plus efficace pour modéliser la dépendance spatiale dans le contexte thématique de cette étude.

Des erreurs de classification liées à l'anisotropie des textures sont particulièrement présentes lors de l'utilisation d'un classifieur de type  $k$ -NN. Mais, ces erreurs ont pu être partiellement réduites en homogénéisant les orientations dans la base de données. La classification par SVM a démontré son intérêt dans ce contexte en gérant plus efficacement la variabilité des orientations et en réduisant ces erreurs. Son utilisation permet ainsi d'éviter ce prétraitement des données consistant à retourner tous les individus à une même orientation, opération qui s'avérerait délicate dans une perspective d'automatisation de la classification.

L'ajout de paramètres issus de la modélisation de la dépendance couleur ainsi que l'homogénéisation des orientations dans la base de données permet d'atteindre des performances plus élevées pour la plupart des modèles. L'analyse des performances par classe révèle toutefois un comportement différent de chacune des classes face à ces modalités. Les classes considérées ont en effet leurs propres caractéristiques en termes de texture, d'orientation et de réponse spectrale.

Par ailleurs, la diversité des pratiques culturales, la limite confuse entre les classes et les séquelles de perturbations naturelles introduisent invariablement des divergences entre la texture observée dans certains peuplements et leur âge réel. L'hypothèse *a priori* de l'existence d'une relation entre l'âge des peuplements et la distribution spatiale des arbres a donc ses limites. Cependant, les modèles proposés s'ajustent la plupart du temps correctement à la texture observée et les erreurs de classification sont principalement dues à ces divergences.

Enfin, plusieurs images satellite THR acquises avec deux capteurs différents (Pléiades et GeoEYE) et à des saisons différentes ont été testées dans cette étude. Les spécificités de ces images en termes de géométrie d'acquisition et de dynamique radiométrique rendent toutefois délicate la formulation de recommandations sur le choix d'un capteur ou d'une saison d'acquisition. Il semble néanmoins que les performances de classification soient plus élevées sur les images d'été que sur les images d'hiver probablement en raison des ombres portées moins marquées dans ces images. Un angle d'incidence faible semble également garantir une meilleure perception des textures grâce à la distance d'échantillonnage plus courte associée.

Les expérimentations réalisées et les conclusions dégagées ci-dessus constituent les principales contributions originales de ce chapitre. Celles-ci ont fait l'objet d'une publication dans [\[Regniers et al., 2014b\]](#). Par ailleurs, nous avons adapté la chaîne de traitement proposée au chapitre II (Figure 2.3 A) au contexte applicatif de la classification des classes d'âge de peuplements forestiers. Nous avons également démontré l'intérêt de la très haute résolution spatiale et de l'utilisation des capteurs Pléiades et GeoEYE pour traiter la problématique présentée.

### III.5.2 Perspectives

Les classes considérées dans cette étude ont montré des comportements différents face aux diverses modalités d'analyse envisagées (SP, COL, SP+COL, SProt, SProt+COL) en raison de leurs caractéristiques spécifiques en termes d'anisotropie, de contenu textural et de réponse spectrale. Or, la stratégie envisagée dans cette étude a consisté à paramétrer les approches d'analyse texturale par la recherche d'un modèle optimal maximisant la discrimination entre les classes. Cette stratégie globale de modélisation est une forme de compromis entre les spécificités propres à chacune des classes. Une perspective intéressante dans ce contexte serait de proposer une stratégie alternative dans laquelle les modèles seraient paramétrés classe par classe afin de mieux s'ajuster à ces particularités. Des



indicateurs de type *Goodness-of-Fit* pourraient être envisagés lors de cette phase de sélection de modèle [[Bentler & Bonett, 1980](#)]. Cela permettrait par exemple de choisir une décomposition en ondelettes, un nombre d'échelles de décomposition et/ou un modèle différents pour chacune des classes. De même, le choix d'un modèle différent pour décrire les dépendances spatiales et les dépendances couleurs pourrait être envisagé.

L'hypothèse *a priori* de l'existence d'une relation entre l'âge des peuplements et la texture a montré ses limites dans cette étude. Cela suggère l'utilité potentielle des modèles multivariés pour l'estimation de variables de structures forestières plus directement liées à la texture. Ce serait le cas par exemple du diamètre des couronnes qui a un impact direct sur la taille des objets à décrire ou de la densité des peuplements qui est directement liée à la distribution spatiale de ces objets.

# Chapitre IV - Application à la détection des parcelles viticoles

<b>IV.1 Introduction.....</b>	<b>80</b>
<b>IV.2 Site d'étude et données .....</b>	<b>81</b>
<b>IV.2.1 Site d'étude et données satellite .....</b>	<b>81</b>
<b>IV.2.2 Sources d'altération de la texture.....</b>	<b>82</b>
<b>IV.2.3 Bases de données de patches de texture .....</b>	<b>84</b>
<b>IV.3 Indexation par CBIR.....</b>	<b>85</b>
<b>IV.3.1 Stratégie d'application des méthodes .....</b>	<b>85</b>
IV.3.1.1 Paramétrisation des matrices de co-occurrence .....	85
IV.3.1.2 Configuration de la transformée en ondelettes.....	87
<b>IV.3.2 Résultats d'indexation .....</b>	<b>87</b>
<b>IV.4 Résultats de classification.....</b>	<b>91</b>
<b>IV.4.1 Segmentation par filtres de Gabor .....</b>	<b>91</b>
<b>IV.4.2 Comparaison des résultats de classification et segmentation.....</b>	<b>93</b>
<b>IV.5 Conclusions et perspectives.....</b>	<b>100</b>
<b>IV.5.1 Conclusions .....</b>	<b>100</b>
<b>IV.5.2 Perspectives.....</b>	<b>101</b>

## IV.1 Introduction

Outre les forêts cultivées évoquées au chapitre précédent, d'autres types de plantations agricoles (verger, vignoble,...) peuvent être détectés dans les images à très haute résolution (THR) grâce aux motifs réguliers qu'ils dessinent dans le paysage. La détection et la caractérisation de ces couverts agricoles sont des enjeux majeurs pour les autorités publiques en charge de la gestion du territoire. En viticulture, la détection des vignobles est utile par exemple à la construction ou à la mise à jour de carte d'occupations du sol, pour la réalisation d'inventaire à l'échelle d'une appellation ou pour le suivi de déclaration de surfaces et de densité de plantation liée aux réglementations locales, nationales ou européennes.

Dans ce contexte, diverses études basées sur des images THR ont exploité avec succès l'aspect structuré des parcelles viticoles en utilisant des outils d'analyse de texture tels que les matrices de co-occurrence ou les variogrammes [Balaguer *et al.*, 2010 ; Warner & Steinmaus, 2005]. Par ailleurs, en raison de l'aspect périodique des rangs de vigne, des analyses de textures basées sur des méthodes fréquentielles ont également démontré leur intérêt pour la détection et la caractérisation des vignobles en permettant en outre d'estimer l'orientation des rangs, la distance inter-rang ou la présence de pieds manquants [Chanussot *et al.*, 2005 ; Ranchin *et al.*, 2001 ; Wassenaar *et al.*, 2002]. Toutefois, dans la plupart de ces études, une connaissance *a priori* du contour des parcelles est souvent nécessaire. Plus récemment, [Rabatel *et al.*, 2008] ont proposé une méthode de détection et de segmentation des parcelles viticoles sans connaissance *a priori* du parcellaire. Cette approche consiste à isoler chaque parcelle individuellement en sélectionnant sa réponse fréquentielle dans le spectre de Fourier au moyen d'un filtre de Gabor adapté.

La plupart de ces études utilisent des images satellite ou aériennes de résolution proche ou inférieure à 0,5 m. Selon le théorème de Shannon-Nyquist, la texture issue de la distribution spatiale des rangs de vignes n'est perceptible dans l'image que si la résolution spatiale est au moins deux fois plus petite que la période de répétition du motif. Dans certaines appellations viticoles françaises et en particulier dans la région bordelaise, la densité de plantation est telle que la distance entre les rangs peut être proche de 1 m. L'utilisation d'images panchromatiques THR telles que celles fournies par le capteur Pléiades (résolution spatiale de 0,7 m) peut donc être problématique.

Dans ce chapitre, des images panchromatiques Pléiades acquises sur différentes appellations viticoles bordelaises sont exploitées afin d'évaluer la capacité des modèles multivariés, sur la base d'une décomposition en ondelettes, à détecter les parcelles viticoles et ce, malgré les limitations potentielles liées au rapport entre résolution spatiale et distance entre les rangs. Après avoir décrit les sites d'étude et les données satellite, les modèles multivariés sont tout d'abord comparés avec les matrices de co-occurrence dans une analyse par indexation d'images afin d'identifier les modèles les plus performants. Dans un second temps, des résultats de classification sont produits et comparés avec ceux obtenus par les matrices de co-occurrence et par la méthode de segmentation présentée dans [Rabatel *et al.*, 2008].

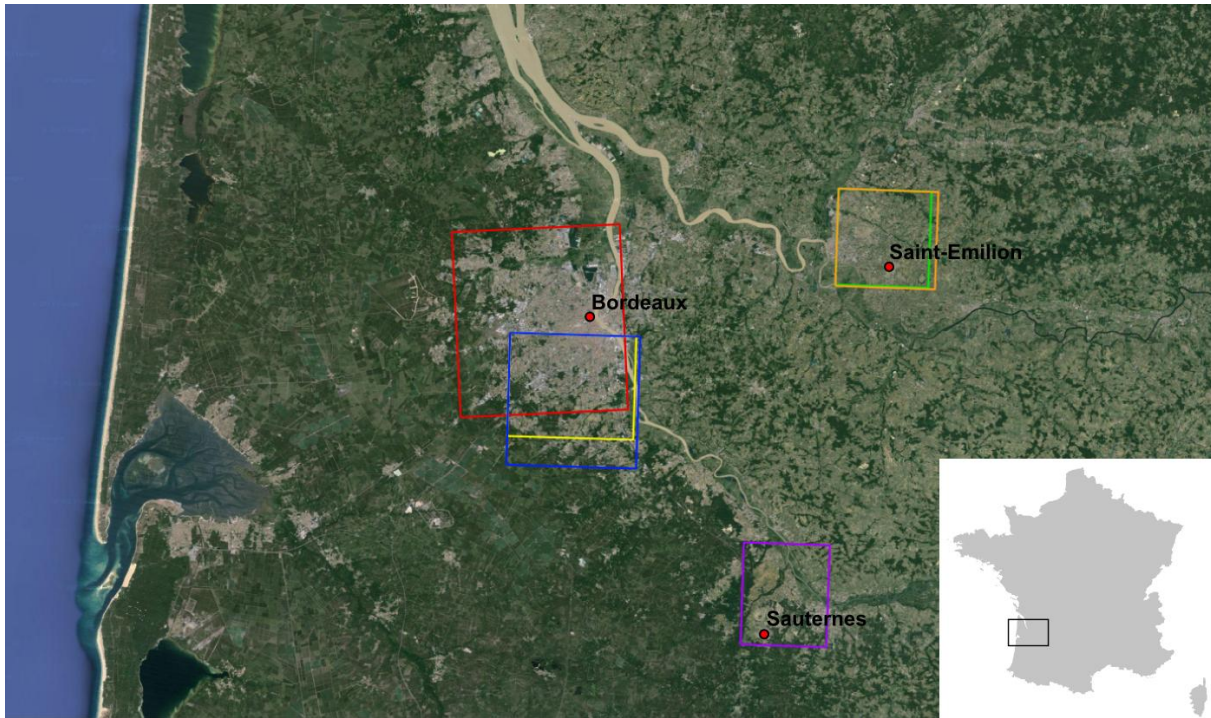


Figure 4.1 : Localisation du site d'acquisition. Les zones encadrées en couleur correspondent aux emprises des images satellite acquises sur la zone d'intérêt.

## IV.2 Site d'étude et données

### IV.2.1 Site d'étude et données satellite

Afin d'analyser les performances des modèles multivariés, six images panchromatiques Pléiades ont été acquises durant l'été 2012 et 2013 sur trois appellations viticoles bordelaises : Pessac-Léognan (22/08/12 - 21/08/13 - 07/10/13), Saint-Emilion (01/08/13 - 03/09/13) et Sauternes (10/09/13). Ces données ont été collectées dans le cadre de la Recette Thématique Utilisateurs du programme ORFEO d'accompagnement Pléiades organisé par le CNES. Ces images ont été fournies après correction géométrique et ortho-rectification avec une résolution radiométrique de 12 bits. La vigne atteignant son pic de développement pendant la saison estivale, le choix de cette période d'acquisition permet de s'assurer d'un meilleur contraste entre le rang et l'inter-rang. La localisation géographique et l'emprise des images sont illustrées à la Figure 4.1.

Comme dans l'étude sur la classification de classes d'âge de forêt, la dynamique radiométrique des images Pléiades a été modifiée de 12 bits à 8 bits dans un souci de facilité de manipulation des images. Cette opération est réalisée de manière à conserver au mieux la dynamique radiométrique de l'image d'origine codée en 12 bits. Les bornes de ré-étalement de l'histogramme sont ainsi fixées sur l'intervalle de l'histogramme dans lequel la dynamique principale des niveaux de gris est concentrée. Les pixels situés en dehors de cet intervalle sont alors saturés à 255 dans les zones de forte réflectance ou fixés à 0 dans les zones de faible réponse spectrale. Les parcelles viticoles et les zones de végétation en général sont peu affectées par cette opération.

Le capteur Pléiades fournit des données THR panchromatiques avec une résolution spatiale de 0,7 m ré-échantillonnée à 0,5 m. Malgré la très haute résolution de ces données, la détection de parcelles viticoles par analyse texturale peut être délicate dans les contextes viticoles champenois, bourguignon




Figure 4.2 : Effet d'atténuation de texture sur un extrait d'une parcelle en Pessac-Léognan (distance inter-rang = 1.1 m) dans une image aérienne de la BD ORTHO 2009 - GSD = 0.5 m (gauche), dans l'image Pléiades du 21/08/13 - GSD = 0.74 m (centre) et dans l'image Pléiades du 07/10/13 – GSD = 0.9 m (droite).

ou bordelais. En effet, ces régions sont caractérisées par des densités de plantation élevées se traduisant par de courtes distances inter-rang. Dans le cas des appellations viticoles bordelaises visées dans cette étude, ces distances sont de l'ordre de 1 à 1,2 m en Pessac-Léognan et de 1,4 à 2 m en Saint-Emilion et Sauternes. Selon la contrainte formalisée dans le théorème de Shannon-Nyquist, ce faible rapport entre distance inter-rang et résolution spatiale entraîne une atténuation de la texture, et ce d'autant plus que la distance inter-rang est faible. Ce phénomène est donc plus marqué en Pessac-Léognan que dans les deux autres appellations. Par ailleurs, ces effets d'atténuation de texture peuvent être accentués par des altérations de l'image liées à la géométrie d'acquisition. Ces différentes observations ont des conséquences sur la capacité non seulement à détecter les parcelles mais aussi à les caractériser en termes d'orientation des rangs, de distance inter-rang ou de pratiques culturales. Ces phénomènes et leurs conséquences dans l'image sont décrits dans la partie suivante.

#### IV.2.2 Sources d'altération de la texture

Le premier phénomène d'altération de texture observé dans les images Pléiades concerne l'apparition d'effets d'aliasing (aspect crénelé des rangs) là où le rapport entre distance inter-rang et résolution spatiale est proche de la limite de Shannon-Nyquist. Cet effet est illustré à la Figure 4.2 pour un extrait de l'image Pléiades du 21/08/13. Il apparaît clairement dans cet extrait que l'aspect fréquentiel des rangs de vigne est perturbé. L'aliasing entraîne en outre une perception erronée de l'orientation des rangs. Il est donc délicat dans ces circonstances de procéder à une caractérisation des parcelles et d'en estimer l'orientation des rangs ou la distance inter-rang.

Si la résolution spatiale des données panchromatiques Pléiades est de 0,7 m, la distance d'échantillonnage au sol (GSD) n'atteindra cette résolution qu'au nadir du satellite pour un angle d'incidence proche de  $0^\circ$ . Dans la plupart des images Pléiades à disposition, cet angle d'incidence est largement supérieur à  $0^\circ$  et la GSD s'en trouve augmentée (Tableau 4.1). Les effets d'aliasing et d'atténuation de la texture sont donc d'autant plus marqués que cette distance d'échantillonnage augmente. Un cas extrême est illustré à la Figure 4.2 par l'extrait de l'image Pléiades du 07/10/13 caractérisée par une GSD de 0,9 m. Dans cette image, l'atténuation est telle que les rangs de vigne deviennent quasiment imperceptibles. Les difficultés de détection des parcelles sont donc particulièrement accrues pour cette image quelle que soit l'approche texturale employée.

Tableau 4.1 : Métadonnées sur la géométrie d'acquisition des images Pléiades.

	Date d'acquisition	Angle d'incidence	Distance d'échantillonnage au sol (GSD)	Elévation solaire
Pessac-Léognan	22/08/12	13.55°	0.73 m	54.69°
	21/08/13	15.62°	0.74 m	55.06°
	07/10/13	33.17°	0.9 m	38.27°
Saint-Emilion	01/08/13	17.45°	0.75 m	60.81°
	03/09/13	18.39°	0.75 m	50.99°
Sauternes	10/09/13	3.73°	0.7	48.71°



Figure 4.3 : Perturbation de la texture liée à l'élévation solaire sur un extrait des images Pléiades du 01/08/13 (gauche) et du 03/09/13 (droite).

Un autre phénomène de perturbation de la texture trouve son origine dans l'angle d'élévation solaire. Celui-ci est d'autant plus faible que l'on s'éloigne du solstice d'été. L'heure de passage du satellite étant la même tous les jours, seul le jour de prise de vue a un impact. Une élévation solaire plus faible au moment de l'acquisition de l'image entraîne une élongation des ombres portées à l'inter-rang ce qui modifie le motif textural. Cette perturbation est variable en fonction de l'orientation des rangs dans le paysage par rapport à la position du satellite. Un exemple de modification de la texture lié à l'élévation solaire et à la position du satellite est illustré à la Figure 4.3 sur deux extraits d'images Pléiades dans la région de Saint-Emilion. Notons que dans cet exemple, d'autres sources de perturbation de la texture peuvent également expliquer les différences observées, telles que les opérations culturales (nettoyage, rognage, pratique d'enherbement, etc.).






Figure 4.4 : Exemples de patches de texture représentatifs des quatre classes d'intérêt issus de la base de données créée à partir de l'image Pléiades du 10/09/13 sur la région de Sauternes.

#### IV.2.3 Bases de données de patches de texture

De manière similaire à l'étude présentée au chapitre III sur la cartographie des forêts, une base de données de patches de texture est créée à partir de chacune des images Pléiades. Ces patches de texture sont utilisés comme données d'apprentissage lors de la classification. Ils sont également exploités lors de l'évaluation des modèles par indexation. Des zones de texture homogène représentatives des différentes classes d'occupation du sol à distinguer sont ainsi repérées dans les images panchromatiques par photo-interprétation. De chacune de ces zones homogènes est extrait un patch de dimension constante égale à  $128 \times 128$  pixels. Un label correspondant à sa classe d'appartenance est ensuite affecté à chacun des patches.

Dans les régions viticoles bordelaises, les vignobles dominent largement le paysage et côtoient essentiellement des couverts de type péri-urbain. Quatre classes principales sont dès lors considérées : la vigne, la forêt, la végétation rase (prairies, parcelles viticoles en régénération, sol nu, etc.) et les zones bâties (Figure 4.4).

On peut remarquer que contrairement à la thématique de différenciation des classes d'âge de forêt évoquée dans le chapitre III, les classes proposées ici sont caractérisées par des motifs texturaux distincts et seule la classe de vigne se caractérise par une texture anisotrope. L'objectif poursuivi ici est de détecter les parcelles viticoles et d'aboutir à une classification binaire « vigne » - « non-vigne ». Le pouvoir de discrimination des différentes approches d'analyse texturale proposées devrait donc être potentiellement plus élevé dans cette thématique que dans la précédente.

Afin d'évaluer la sensibilité des modèles à l'orientation des textures, une seconde base de données de patches est créée pour chaque image Pléiades en opérant une rotation sur les patches de texture anisotrope (ici les patches de vigne) de sorte à forcer leur orientation dominante à 0°. Cette opération est réalisée de manière automatique au moyen d'un tenseur de structure en estimant l'orientation à partir du premier vecteur propre de la matrice de covariance des gradients [Bigun *et al.*, 1991].

## IV.3 Indexation par CBIR

Avant de présenter les résultats d'indexation, il nous faut revenir sur la paramétrisation des méthodes à adapter en fonction du contexte de l'application étudiée. Cette étape concerne la distance entre paires de sites et le choix des descripteurs pour les matrices de co-occurrence (GLCMs) ainsi que le nombre d'échelles de la décomposition en ondelettes dans le cas des modèles multivariés.

### IV.3.1 Stratégie d'application des méthodes

#### IV.3.1.1 Paramétrisation des matrices de co-occurrence

La même procédure de sélection des paramètres que celle appliquée dans le chapitre III est utilisée dans ce contexte. Deux paramètres sont à sélectionner : les descripteurs texturaux et la distance entre paires de sites. La taille de la fenêtre d'analyse équivaut à la dimension des patches (128×128 pixels) et le nombre de niveaux de gris considéré pour le calcul des GLCMs est maintenu à 256.

##### A. Sélection des descripteurs

Comme précédemment, un ensemble de sept descripteurs est évalué : l'énergie, l'entropie, le contraste, la corrélation, l'homogénéité, la moyenne et la variance. Ces sept descripteurs sont déterminés pour tous les patches de la base de données en fixant la distance à 1 pixel et en moyennant les paramètres sur les quatre orientations. Une analyse en composantes principales (ACP) est ensuite réalisée pour identifier les descripteurs qui contribuent le plus aux premières composantes.

Les résultats de l'ACP obtenus sur les données de l'image Pléiades du 10/09/13 sont présentés à la Figure 4.5. Les couples de descripteurs homogénéité/entropie et variance/corrélation apparaissent comme ceux contribuant le plus à la première et à la deuxième composante principale respectivement. Ces quatre descripteurs sont dès lors sélectionnés pour la suite de l'analyse. La même analyse réalisée sur les autres bases de données aboutit aux mêmes conclusions. Ces descripteurs sont également appliqués pour les GLCMs sur ondelettes (WCF). Remarquons aussi que trois de ces quatre paramètres ont également été sélectionnés lors de l'étude sur les classes d'âge de forêt. La moyenne utilisée précédemment est ici remplacée par la variance.

##### B. Sélection de la distance

Un test d'indexation est mené en faisant varier la distance de déplacement entre 1 et 5 pixels et en moyennant les descripteurs sur les quatre orientations. Les quatre descripteurs préalablement sélectionnés (l'homogénéité, l'entropie, la corrélation et la variance) sont utilisés dans ce test. Les résultats sont affichés à la Figure 4.6.






Figure 4.5 : Analyse en composantes principales sur les descripteurs de GLCM calculés à partir de la base de données issue de l'image Pléiades du 10/09/13. Les première et deuxième composantes principales sont représentées à gauche, les première et troisième à droite.




Figure 4.6 : Taux de reconnaissance moyen (ARR) obtenus avec les matrices de co-occurrence en fonction de la distance entre paires de site pour les bases de données issues de l'image Pléiades du 22/08/12 (gauche) et du 10/09/13 (droite).

Les meilleurs taux de reconnaissance (ARR) sont obtenus avec une distance comprise entre 1 et 2 pixels en fonction de l'image d'origine de la base de données. Ce résultat est cohérent avec la taille des objets à détecter. Celle-ci est liée à la distance inter-rang qui varie d'une image à l'autre en fonction de l'appellation viticole étudiée. Ainsi, l'image Pléiades du 22/08/12 acquise en Pessac-Léognan (Figure 4.6 – gauche) est caractérisée par des distances inter-rang courtes proches du mètre. Le déplacement entre paires de pixels à considérer doit donc être proche de 1 pixel (0,5 m) pour permettre de capter les contrastes. Dans le cas de l'image Pléiades du 10/09/13 acquise en Sauternes, les distances inter-rangs sont plus larges (entre 1,4 et 2 m) et le déplacement entre pixels à considérer est compris entre 1 et 2 pixels. Une distance de déplacement de 1 pixel est choisie pour toutes les images. Ce même déplacement de 1 pixel est appliqué dans le cas des GLCMs sur ondelettes (WCFs).

### IV.3.1.2 Configuration de la transformée en ondelettes

Comme dans l'approche utilisée au chapitre III, les modèles multivariés sont appliqués sur les sous-bandes issues d'une transformée en ondelettes discrète (DWT) avec une base d'ondelettes Daubechies db4. Les patches étant de taille 128×128 pixels, le nombre d'échelles de la décomposition est limité à 2 produisant ainsi six sous-bandes à modéliser (2 échelles × 3 orientations). Un voisinage spatial de dimension 3×3 est considéré dans les sous-bandes pour caractériser les dépendances spatiales.

### IV.3.2 Résultats d'indexation

La procédure d'évaluation des modèles par indexation est réalisée sur des sous-ensembles de la base de données dans lesquels les patches sont sélectionnés aléatoirement afin d'équilibrer les classes (25 patches par classes). Cette procédure est répétée sur 100 itérations. Un taux de reconnaissance ARR est déterminé à chaque itération en récupérant les distances mesurées entre chaque paire de patches. A la fin des 100 itérations, un ARR moyen est calculé pour comparer les méthodes. Les courbes de Rappel/Précision sont quant à elles déterminées sur l'ensemble de la base de données sans passer par cette procédure itérative.

L'analyse d'indexation est menée sur les mêmes configurations d'analyse de texture qu'au chapitre III, à savoir :

- La matrice de co-occurrence en concaténant dans un même vecteur les descripteurs calculés dans les quatre orientations (GLCM),
- La matrice de co-occurrence en moyennant les descripteurs sur les quatre orientations garantissant une meilleure invariance à la rotation (GLCM\_INV),
- La matrice de co-occurrence calculée sur les sous-bandes d'ondelettes en moyennant les descripteurs sur les quatre orientations (WCF),
- Le modèle Gaussien multivarié (SCM),
- Le modèle SIRV Gaussien (SIRVgauss),
- Le modèle SIRV de distribution G0 (SIRVg0),
- La Gamma multivariée sur copule Gaussienne (GCG) et
- La Gaussienne Généralisée Multivariée (MGG).

Les taux de reconnaissance moyen (ARR) pour toutes les méthodes d'analyse de la dépendance spatiale sont présentés à la Figure 4.7 pour quatre images Pléiades. Ces résultats sont obtenus avec la base de données d'origine (BD) et avec la même base de données dans laquelle les patches de texture ont été réorientés en forçant leur orientation à 0° (BDrot).

La comparaison des performances d'indexation montre que la capacité relative des différentes méthodes à mieux discriminer les textures dans ce contexte est variable d'une image à l'autre. Cette variabilité est à mettre en relation avec les caractéristiques d'acquisition de ces images, et en particulier avec la GSD (Tableau 4.1). La distance d'échantillonnage est en effet tellement proche de la taille des objets (les rangs de vigne) qu'une faible variation de ce facteur a une influence significative sur la capacité des méthodes à décrire le motif textural. Ainsi, l'analyse réalisée sur la base de données BD issue de l'image Pléiades du 10/09/13 en Sauternes (distance inter-rang moyenne proche de 2 m et GSD égale à 0,7 m) affiche les taux de reconnaissance les plus élevés (ARR proche de 90% avec GLCM\_INV). A l'inverse, l'image du 07/10/13 acquise en Pessac-Léognan (distance

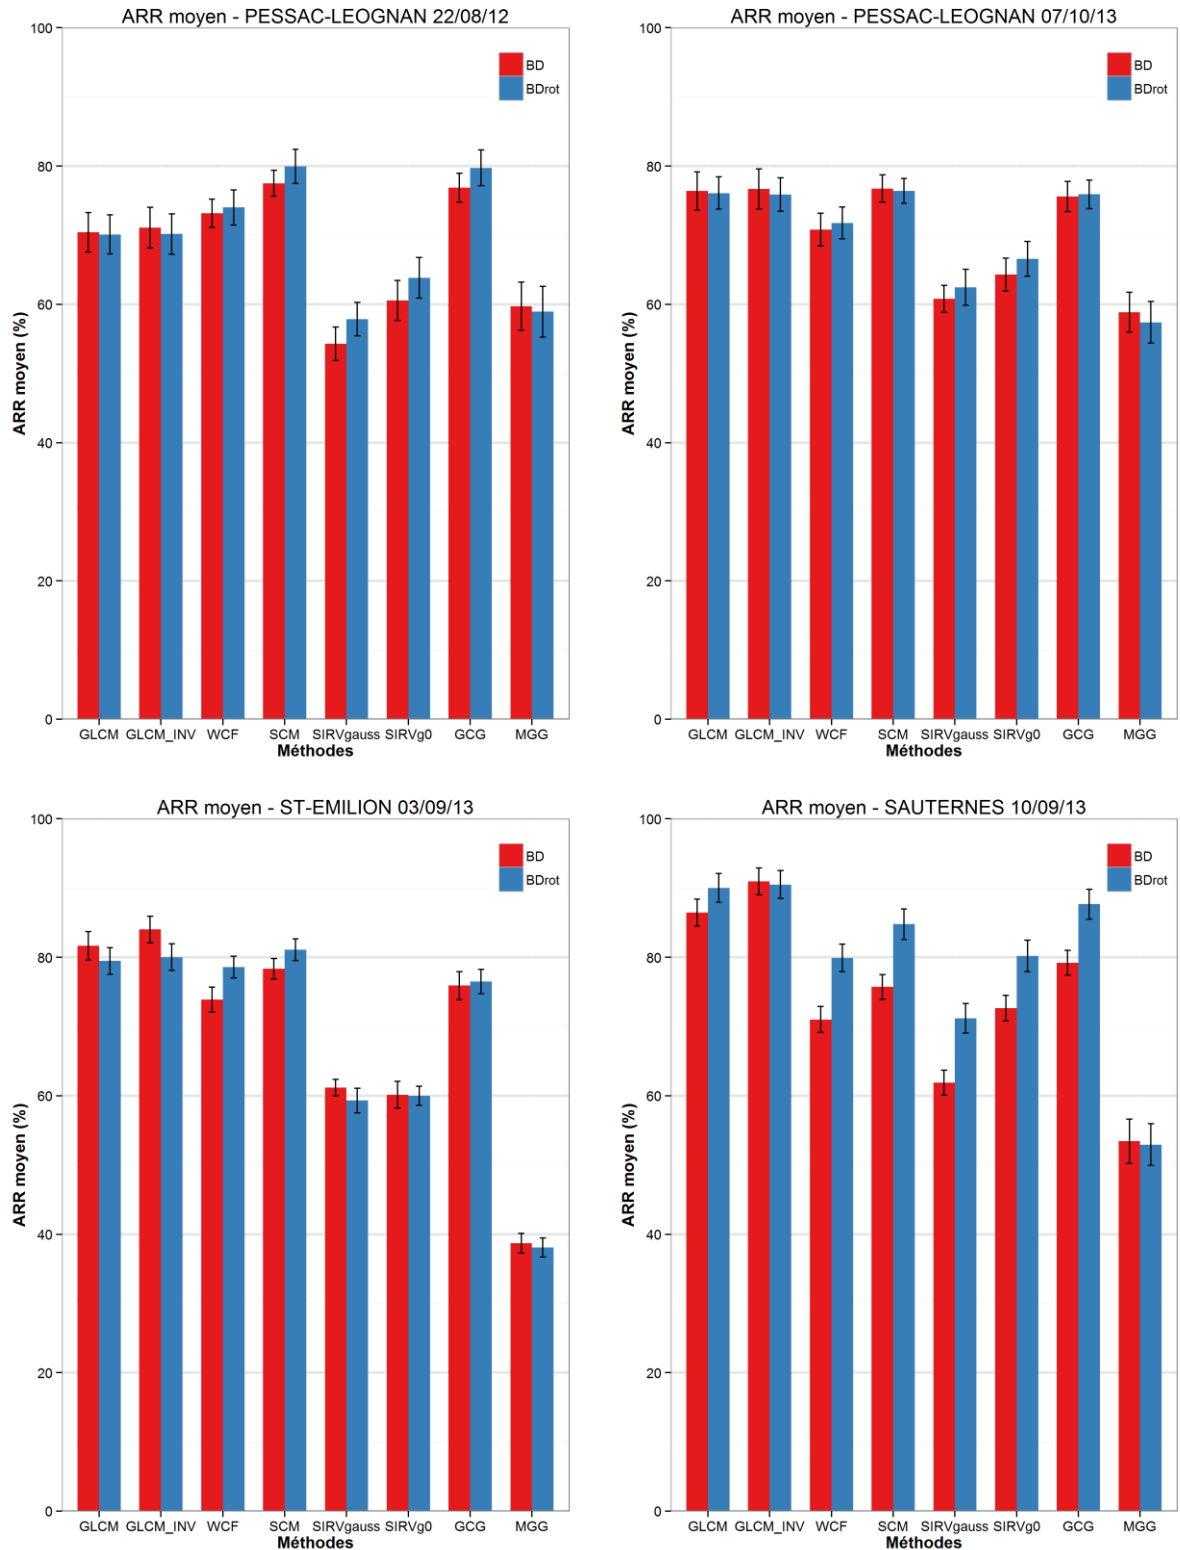


Figure 4.7 : Taux de reconnaissance moyens ARR obtenus par indexation sur les bases de données de patchs de texture originales (BD - rouge) et réorientées (BDrot - bleu) des patchs. Les barres d'erreur indiquent l'écart-type sur 100 itérations.

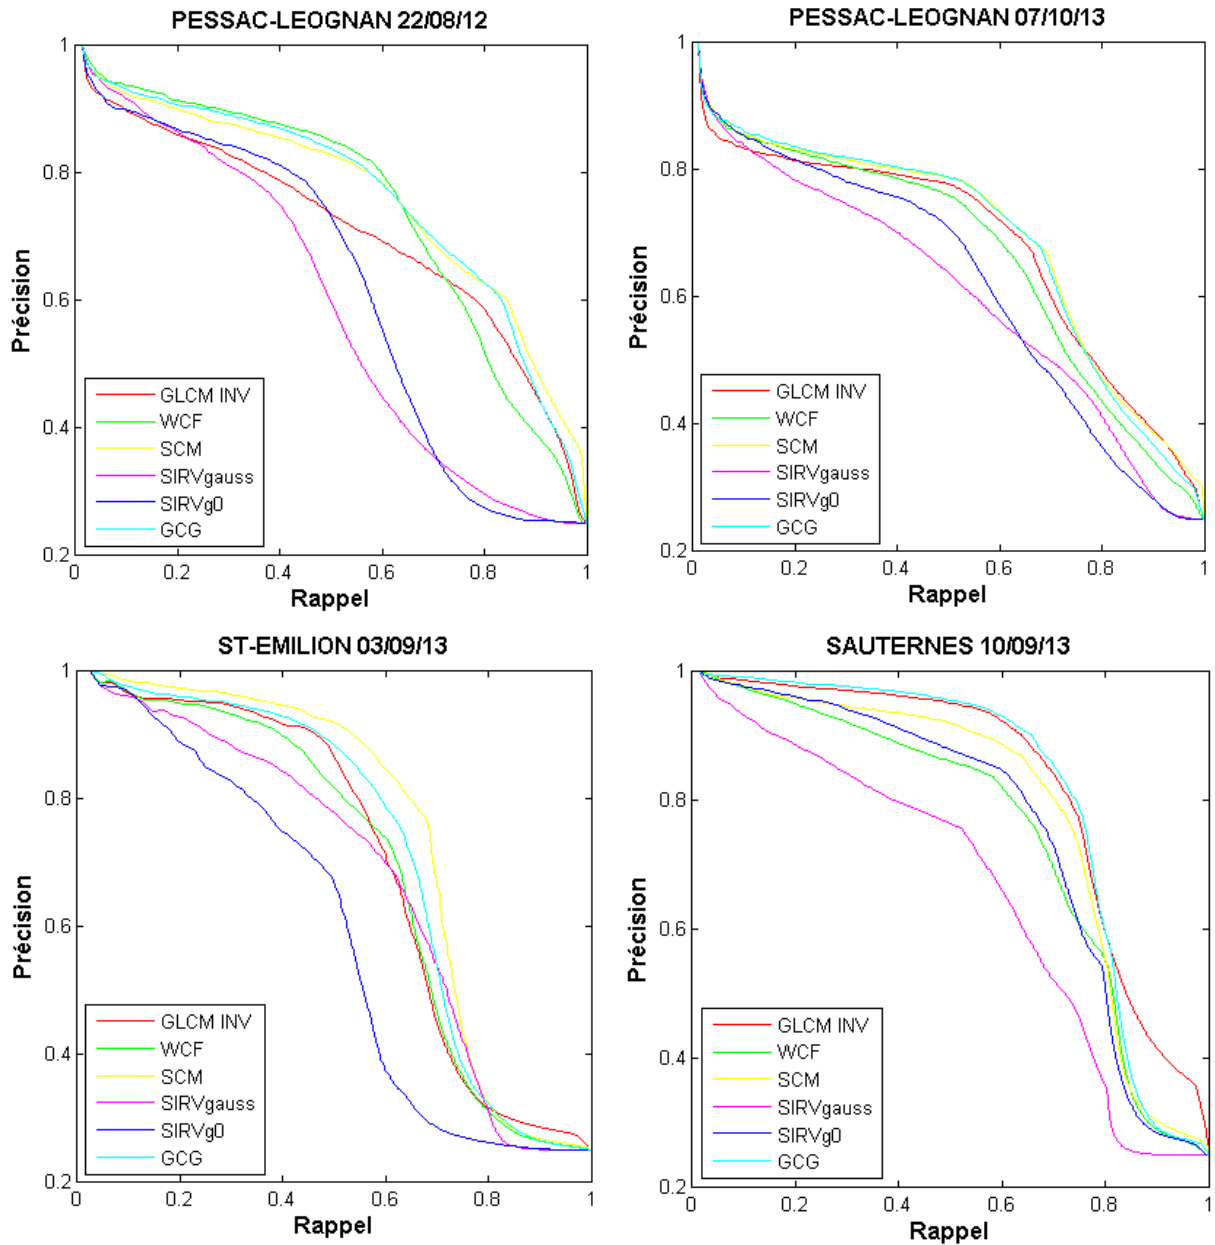


Figure 4.8 : Courbes Rappel/Précision obtenues sur les bases de données BD issues de quatre images Pléiades.

inter-rang moyenne proche de 1,2 m et GSD égale à 0,9 m) révèle les performances d'indexation les plus faibles (ARR proche de 75% avec SCM et GLCM\_INV). Pour cette image, l'atténuation de la texture dans les parcelles de vigne est telle que toutes les approches peinent à séparer les classes considérées. De manière générale, les modèles multivariés semblent mieux s'en sortir que les GLCMs lorsque le rapport entre distance inter-rang moyenne et GSD est faible. C'est le cas par exemple sur l'image en Pessac-Léognan du 22/08/12 (distance inter-rang moyenne proche de 1,2 m et GSD égale à 0,73 m).

On remarque également que les différences entre les bases de données BD et BDrot sont faibles pour toutes les images sauf celle du 10/09/13. Il semble donc que contrairement à la thématique des classes d'âge de forêt, ce facteur d'orientation n'ait pas d'influence sur la capacité de détecter des parcelles viticoles. Cela peut être dû aux effets d'atténuation de la texture qui contribue à minimiser la perception des rangs et donc de l'orientation, mais aussi au fait que dans ce contexte seule la classe de

vigne arbore une texture anisotrope. Il y a donc moins de risques de confusion, au contraire de la thématique forêt où plusieurs classes étaient caractérisées par des textures directionnelles. Cela explique probablement aussi les meilleures performances obtenues dans cette thématique. On constate néanmoins que les performances des modèles multivariés sont améliorées en homogénéisant les orientations dans le cas de l'image du 10/09/13. A nouveau, le rapport distance inter-rang/GSD justifie probablement en partie ce comportement, les rangs de vigne étant plus nettement perceptibles dans cette image.

Des différences notables sont observées entre les performances obtenues par l'ensemble des modèles multivariés. Deux approches de modélisation se comportent mieux : le modèle Gaussien SCM et la Gamma sur Copule Gaussienne (GCG). Alors qu'ils s'étaient distingués dans la thématique « forêt », les modèles basés sur les SIRVs (SIRVgauss et SIRVg0) semblent ici avoir plus de difficultés que les deux modèles précédents à séparer efficacement les classes considérées. Cela confirme la nécessité d'adapter l'approche de modélisation au contexte et l'intérêt de cette analyse d'indexation pour identifier les modèles les plus performants. Les taux de reconnaissance moyens sont cependant plus élevés pour ces modèles SIRVs dans le cas de l'image du 10/09/13 moins affectée par les problèmes d'atténuation de texture. Il se pourrait donc que ces modèles soient plus sensibles à ces perturbations. Le modèle MGG se comporte nettement moins bien que les autres modèles multivariés ce qui confirme à nouveau les faibles performances de ce modèle observées par [\[Verdoolaege et al., 2008\]](#) lors de la modélisation des dépendances spatiales.

Pour mieux saisir le comportement général de ces approches, l'analyse menée sur les taux de reconnaissance est complétée par les courbes de Rappel/Précision. Cette représentation graphique permet de mieux appréhender les réponses des modèles dans un contexte de classification où seules les quelques images les plus proches sont prises en compte dans les règles de décision. Ces courbes sont présentées à la Figure 4.8. On perçoit aussi nettement sur ces courbes les comportements variables des modèles en fonction de l'image Pléiades utilisée. Ainsi, sur les deux images acquises en Pessac-Léognan, soit là où la distance inter-rang est la plus courte, on remarque que la précision diminue rapidement (coin supérieur gauche) alors que le rappel augmente peu. Cela signifie que même en ne considérant qu'un faible nombre d'images proches, des erreurs d'indexation risquent de se produire. A l'inverse, sur l'image en Saint-Emilion et de manière encore plus marquée sur l'image en Sauternes, la précision se maintient à des niveaux élevés lorsque le rappel augmente. Dans ces cas, les modèles sont suffisamment performants et les textures suffisamment perceptibles pour permettre des taux de bonnes détections élevés pour un faible nombre d'images proches. Bien entendu, la précision diminue lorsque le nombre d'images considéré dans l'indexation atteint un seuil se rapprochant du nombre d'images par classe.

Comme cela fût constaté dans l'analyse des ARR, les différences les plus marquées entre les meilleurs modèles multivariés et les GLCMs sont observés pour les images en Pessac-Léognan (22/08/12) et Saint-Emilion (03/09/13). Pour ces images, le rapport distance inter-rang/GSD est suffisamment faible pour provoquer une atténuation significative de la texture, mais aussi suffisamment élevé pour maintenir une information texturale dans l'image, information qui semble mieux décrite par les modèles multivariés que par les GLCMs. C'est donc bien dans ce cas intermédiaire que les modèles multivariés sont les plus performants. Pour les autres images testées, le comportement des meilleurs modèles est au moins équivalent à celui des GLCMs. Ces courbes de Rappel/Précision confirment les bonnes performances des modèles SCM et Gamma sur Copule Gaussienne (GCG). On peut noter aussi le bon comportement des WCFs notamment dans l'image en Pessac-Léognan (22/08/12) ce qui

indique bien que l'information contenue dans les sous-bandes de la décomposition en ondelettes peut être plus riche que celle contenue dans le domaine des niveaux de gris.

Les modèles multivariés identifiés grâce à cette analyse d'indexation sont donc le modèle Gaussien avec estimateur SCM de la matrice de covariance et le modèle Gamma sur Copule Gaussienne. Dans la section suivante, ces modèles sont comparés avec les GLCMs dans un contexte de classification.

## IV.4 Résultats de classification

La stratégie envisagée ici se place dans un contexte de classification supervisée orientée objet où aucune connaissance *a priori* du terrain n'est disponible (voir paragraphe II.3.1.1). Les bases de données de patches de texture sont donc employées comme données d'apprentissage. Une étape de pré-segmentation de l'image par Mean-Shift est opérée afin de définir les contours des régions à classifier [Regniers *et al.*, 2014a].

Avant de réaliser la classification, les bases de données de patches sont préalablement allégées afin de limiter le nombre de patches de vigne d'apprentissage et ainsi d'accélérer le processus de classification. Pour ce faire, une sélection aléatoire de patches est menée en se basant sur un critère d'orientation. On suppose en effet que de meilleures performances de classification seront obtenues en maintenant une forme d'exhaustivité des orientations dans la base de données. L'orientation des rangs est estimée pour chaque patch par le biais du tenseur de structure avec un indice de confiance sur le degré d'anisotropie [Bigun *et al.*, 1991]. Les patches sont répartis en 10 classes : 9 classes d'orientation définies par des intervalles entre 0 et 180° par pas de 20° et une classe de parcelles mitées. Cette dernière classe correspond aux parcelles viticoles dans lesquelles de nombreux pieds de vigne sont manquants en raison de l'âge de la parcelle ou suite à des dégâts provoqués par des maladies ou des perturbations naturelles. L'absence de multiples pieds sur les rangs perturbe l'aspect orienté de la texture et s'accompagne généralement d'un faible indice de confiance sur l'estimation de l'orientation. La base de données d'apprentissage est ensuite constituée en sélectionnant aléatoirement 25 patches par classe aboutissant à un total de maximum 325 patches (10\*25 pour la vigne et 3\*25 pour les classes de forêt, zones bâties et végétation rase).

Les résultats de classification pour les GLCMs et les modèles SCM et GCG sont obtenus en utilisant plusieurs classifieurs : les  $k$ -NN et les SVMs pour les GLCMs et le maximum de vraisemblance et les SVMs pour les modèles multivariés. Ces résultats sont également comparés à une méthode de référence de segmentation des parcelles viticoles proposée par [Rabatel *et al.*, 2008] et basée sur l'utilisation de filtres de Gabor. Cette méthode de segmentation est dans un premier temps décrite avant de présenter les résultats de classification/segmentation et leur discussion.

### IV.4.1 Segmentation par filtres de Gabor

Cette approche de segmentation non-supervisée se base sur la méthode proposée par [Rabatel *et al.*, 2008]. Celle-ci tire directement profit de la structure fréquentielle des rangs de vigne. Le principe général est d'appliquer un filtre sélectif de Gabor dans l'espace transformé de Fourier en centrant ce filtre sur le pic de réponse fréquentielle correspondant à chaque parcelle afin d'en récupérer les contours. Cette procédure se déroule en plusieurs étapes décrites ci-dessous.




Figure 4.9 : (A) image d'origine, (B) spectre de Fourier avec les trois pics de fréquence les plus élevés, (C) image binaire résultant de la segmentation, (D-E-F) résultat de la transformée de Fourier inverse appliquée sur le spectre filtré par un filtre Gabor centré sur les trois pics de fréquence les plus élevés.

L'image d'origine est tout d'abord normalisée en fixant la moyenne et l'écart-type à 128 et 90 respectivement. Cette opération est réalisée pixel à pixel en déterminant les moyenne et écart-type locaux dans une fenêtre glissante. Ce prétraitement permet de s'assurer de la robustesse des étapes suivantes aux effets liés à la variation de dynamique radiométrique entre les images, en particulier au niveau des inter-rangs.

Afin de pouvoir appliquer efficacement le filtrage de Gabor sur le spectre de Fourier, il faut éviter que celui-ci soit saturé en considérant un trop grand nombre de parcelles à la fois. L'image à segmenter est donc préalablement découpée en tuiles de dimension 500×500 pixels afin d'analyser un nombre restreint de parcelles. Dans la suite, les opérations décrites sont appliquées sur chaque tuile issue du découpage. Un autre aspect à prendre en compte lors de l'analyse du spectre de Fourier concerne les fréquences liées aux bords de l'image entraînant l'apparition de lignes horizontale et verticale se croisant au centre du spectre. Pour éviter ces perturbations, une fenêtre de Hanning est utilisée afin de générer une atténuation des niveaux de gris en bordure d'image avant l'application de la transformée de Fourier.

Par sa forme Gaussienne, le filtre de Gabor (paragraphe I.3.2.2) appliqué dans l'espace de Fourier agit comme un filtre passe-bande sélectionnant une gamme de fréquence autour de sa fréquence centrale. L'étendue des fréquences sélectionnées varie en fonction d'un paramètre  $\sigma$  définissant la largeur de l'enveloppe Gaussienne du filtre. Pour détecter chaque parcelle de vigne dans l'image de départ, les pics présents dans le spectre de Fourier sont parcourus un à un (Figure 4.9 B). A chaque itération, le



pic le plus élevé est identifié et un filtre de Gabor centré sur la fréquence du pic est appliqué. Une transformée de Fourier inverse sur le spectre filtré permet de récupérer une image dans laquelle apparaissent uniquement les pixels de la ou des parcelles correspondant au pic (Figure 4.9 D-E-F). Un seuil  $S_1$  est ensuite employé pour produire une image binaire dans laquelle chaque composante connexe définit un objet correspondant idéalement à l'emprise d'une parcelle (Figure 4.9 C). Plusieurs objets peuvent être détectés en une seule itération s'ils partagent les mêmes caractéristiques de fréquence et d'orientation dans l'image. Les objets sont éliminés de l'image d'origine en fixant les valeurs de ses pixels à une valeur moyenne de 128. Le processus est alors réitéré en récupérant le pic de fréquence suivant. La condition d'arrêt du processus itératif est atteinte lorsque le rapport entre amplitude maximum et moyenne du spectre est inférieur à un seuil  $S_2$  prédéfini.

Toutefois, il se peut que les objets détectés n'aient pas exactement les caractéristiques fréquentielles du filtre employé mais plutôt une fréquence proche incluse dans l'étendue définie par l'enveloppe Gaussienne. Pour affiner la qualité de la segmentation, un deuxième filtre de Gabor est appliqué pour chaque objet détecté sur un extrait de l'image d'origine défini autour de cet objet. Les dimensions de cette sous-image correspondent aux dimensions de l'objet auxquelles on rajoute une marge  $M$  de taille définie au préalable. Dans cette sous-image, tous les pixels hormis ceux précédemment détectés sont fixés à une valeur de 128. Seul le pic correspondant à cette parcelle apparaît alors dans le spectre de Fourier permettant d'affiner la détection de ses contours.

Cette stratégie d'implémentation diffère quelque peu de celle plus complète présentée dans [\[Rabatel et al., 2008\]](#). Ces auteurs ont en effet proposé de répéter le filtrage sur une sous-image jusqu'à ce que l'objet détecté ne touche plus les bords de la sous-image. A chaque itération, les marges appliquées autour de l'objet sont incrémentées garantissant ainsi de récupérer la totalité de chaque parcelle. Dans notre cas, cette opération n'est réalisée qu'une seule fois avec des marges fixes. Par conséquent, des erreurs de détection peuvent apparaître en particulier à proximité des bords des tuiles issues du découpage initial de l'image.

Les avantages de cette méthode de segmentation par rapport aux approches de classification supervisée sont qu'elle ne nécessite pas d'apprentissage et que les parcelles détectées sont généralement individualisées permettant ainsi de réaliser des analyses plus approfondies de caractérisation de ces parcelles. Néanmoins, plusieurs paramètres demandent à être fixés tels que l'étendue  $\sigma$  du filtre de Gabor, le seuil  $S_1$  à appliquer sur l'image filtrée et le seuil  $S_2$  définissant la condition d'arrêt. Ces paramètres rendent l'automatisation de cette approche complexe. Une procédure d'essai-erreur est ainsi nécessaire pour les fixer et les adapter au contexte de l'image et de l'appellation étudiée.

#### IV.4.2 Comparaison des résultats de classification et segmentation

La stratégie de classification employée ici correspond à une classification supervisée orientée objet (voir paragraphe II.3.1.1). Afin de déterminer les contours des régions à classer, une pré-segmentation par Mean-Shift est tout d'abord opérée sur l'image. Pour éviter que les contours ne suivent les rangs de vigne créant ainsi des régions de forme irrégulière, les images sont préalablement filtrées par un filtre moyenneur de taille  $3 \times 3$ . Le paramétrage de cet algorithme de segmentation est identique pour toutes les images traitées en considérant un rayon  $r$  de taille 5, un intervalle de niveaux de gris  $s$  égal à 6 et une taille minimale de région  $t$  fixée à 600 pixels.

Une fois la pré-segmentation obtenue, la classification est réalisée au moyen de différents classifieurs. Dans le cas des GLCMs, les classifieurs  $k$ -NN ( $k = 10$ ) et SVM sont utilisés à partir des distances mesurées entre les descripteurs issus des patches d'apprentissage et ceux issus des régions obtenues par la pré-segmentation. La dimension de ces régions peut être problématique pour la méthode des GLCMs. En effet, un faible nombre de co-occurrences par rapport au nombre de niveaux de gris génère des matrices clairsemées et des descripteurs d'Haralick potentiellement moins performants (forte variance d'estimation). Une solution serait alors de diminuer le nombre de niveaux de gris de l'image. Toutefois, nous avons préféré maintenir la dynamique radiométrique à 256 niveaux de gris pour éviter de réduire le contraste entre les rangs de vigne et les inter-rangs et ainsi risquer d'accentuer artificiellement l'atténuation des textures déjà présente dans les images. Pour les modèles multivariés SCM et GCG, les classifieurs par maximum de vraisemblance et par SVM sont comparés. Dans chaque région déterminée par la pré-segmentation, un critère de vraisemblance est estimé à partir des observations de la dépendance spatiale et des modèles issus de chaque patch d'apprentissage. La classe du patch maximisant ce critère est affectée à la région. Dans le cas des SVMs, les distances mesurées entre les modèles estimés pour chaque patch d'apprentissage sont injectés dans un noyau Gaussien afin d'identifier les vecteurs de support de chacune des classes. Pour chaque région à classifier, les paramètres des modèles multivariés sont ensuite estimés. La distance la plus courte mesurée entre ces paramètres et les vecteurs de support de chacune des classes détermine alors la classe à laquelle la région appartient. Le paramètre  $\sigma$  définissant l'étendue du noyau Gaussien est fixé de telle sorte à maximiser les performances de classification.

Les résultats de classification et de segmentation obtenus avec les différentes méthodes proposées sont présentés pour un extrait d'image Pléiades en Saint-Emilion (Figure 4.9), en Sauternes (Figure 4.10) et en Pessac-Léognan (Figure 4.11). Les précisions de classification relatives à ces résultats sont quant à elles résumées dans le Tableau 4.2. Les résultats présentés ont subi une phase de post-traitement au cours de laquelle un seuil de surface minimum des composantes connexes est appliqué pour éliminer les objets de petites tailles. Une ouverture (opération de morphologie mathématique) est également utilisée pour lisser le résultat et rendre le contour des objets plus régulier.

Dans l'ensemble, les méthodes faisant appel à des paramètres de texture (GLCM et modèles multivariés) révèlent des performances de détection supérieures à la méthode par filtre de Gabor avec une précision du producteur (PA) généralement supérieure à 90% pour les trois extraits d'image analysés. Cette moindre performance des filtres de Gabor peut s'expliquer par plusieurs facteurs liés à la méthode proprement dite mais aussi au faible contraste entre le rang et l'inter-rang dans l'image. La présence de pieds manquants interrompt localement la fréquence dans certaines parcelles et rend délicate la détection de celles-ci par une analyse dans le spectre de Fourier. Par conséquent, des trouées apparaissent dans le résultat de segmentation, en particulier dans le cas des images en Saint-Emilion (Figure 4.9) et en Sauternes (Figure 4.10). Les parcelles de petite taille y sont également difficilement détectables par cette méthode en raison du faible pic qu'elles engendrent dans le spectre de Fourier. Dans le cas de l'image en Pessac-Léognan (Figure 4.11), la plus faible distance inter-rang atténue significativement la réponse fréquentielle des parcelles et leur détection par cette méthode y est particulièrement compliquée. La PA des filtres de Gabor est ainsi plus faible sur cette image (68%) que sur les autres. Par ailleurs, comme mentionné précédemment, les effets engendrés par le découpage en tuiles de l'image à segmenter n'ont pas été gérés dans notre implémentation de l'algorithme proposé par [Rabatel *et al.*, 2008]. Une parcelle découpée sur plusieurs tuiles peut être partiellement mal détectée. Ceci explique en partie les différences de PA entre cette méthode et les approches par classification.

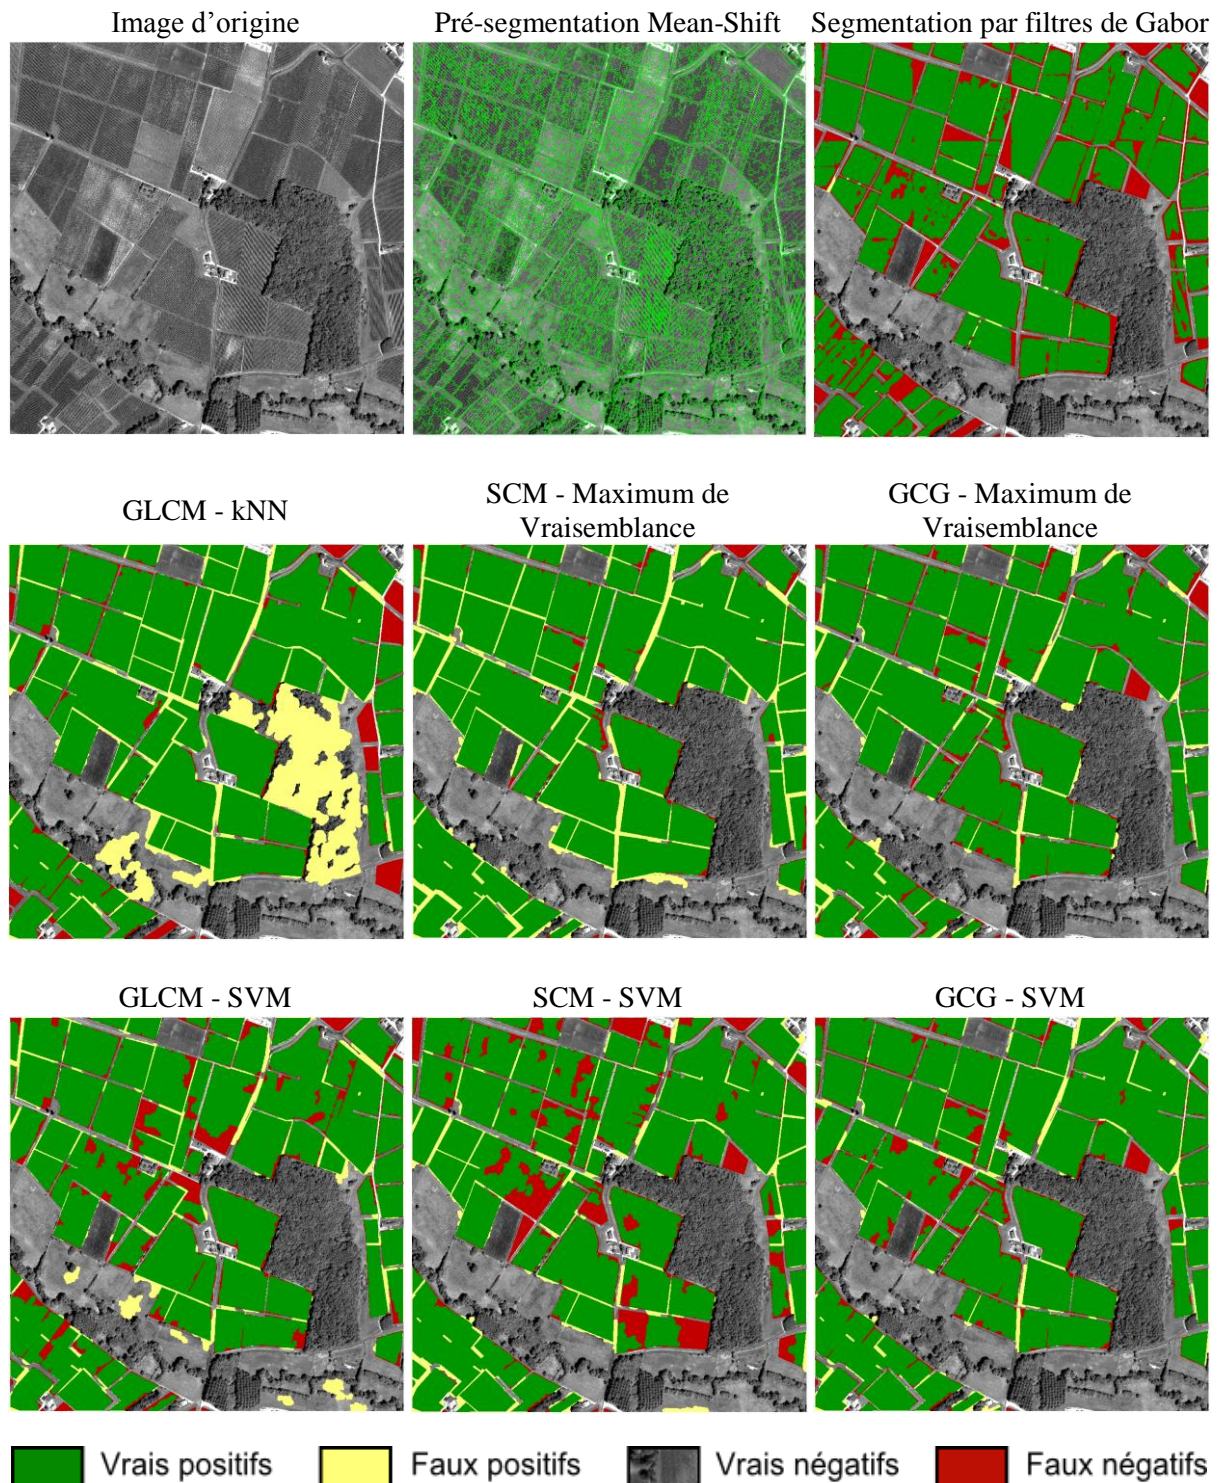


Figure 4.9 : Résultats de classification sur un extrait de l'image Pléiades du 01/08/13 en Saint-Emilion.  
 Les contours de couleur verte désignent les frontières de région définies par l'algorithme de Mean-Shift.



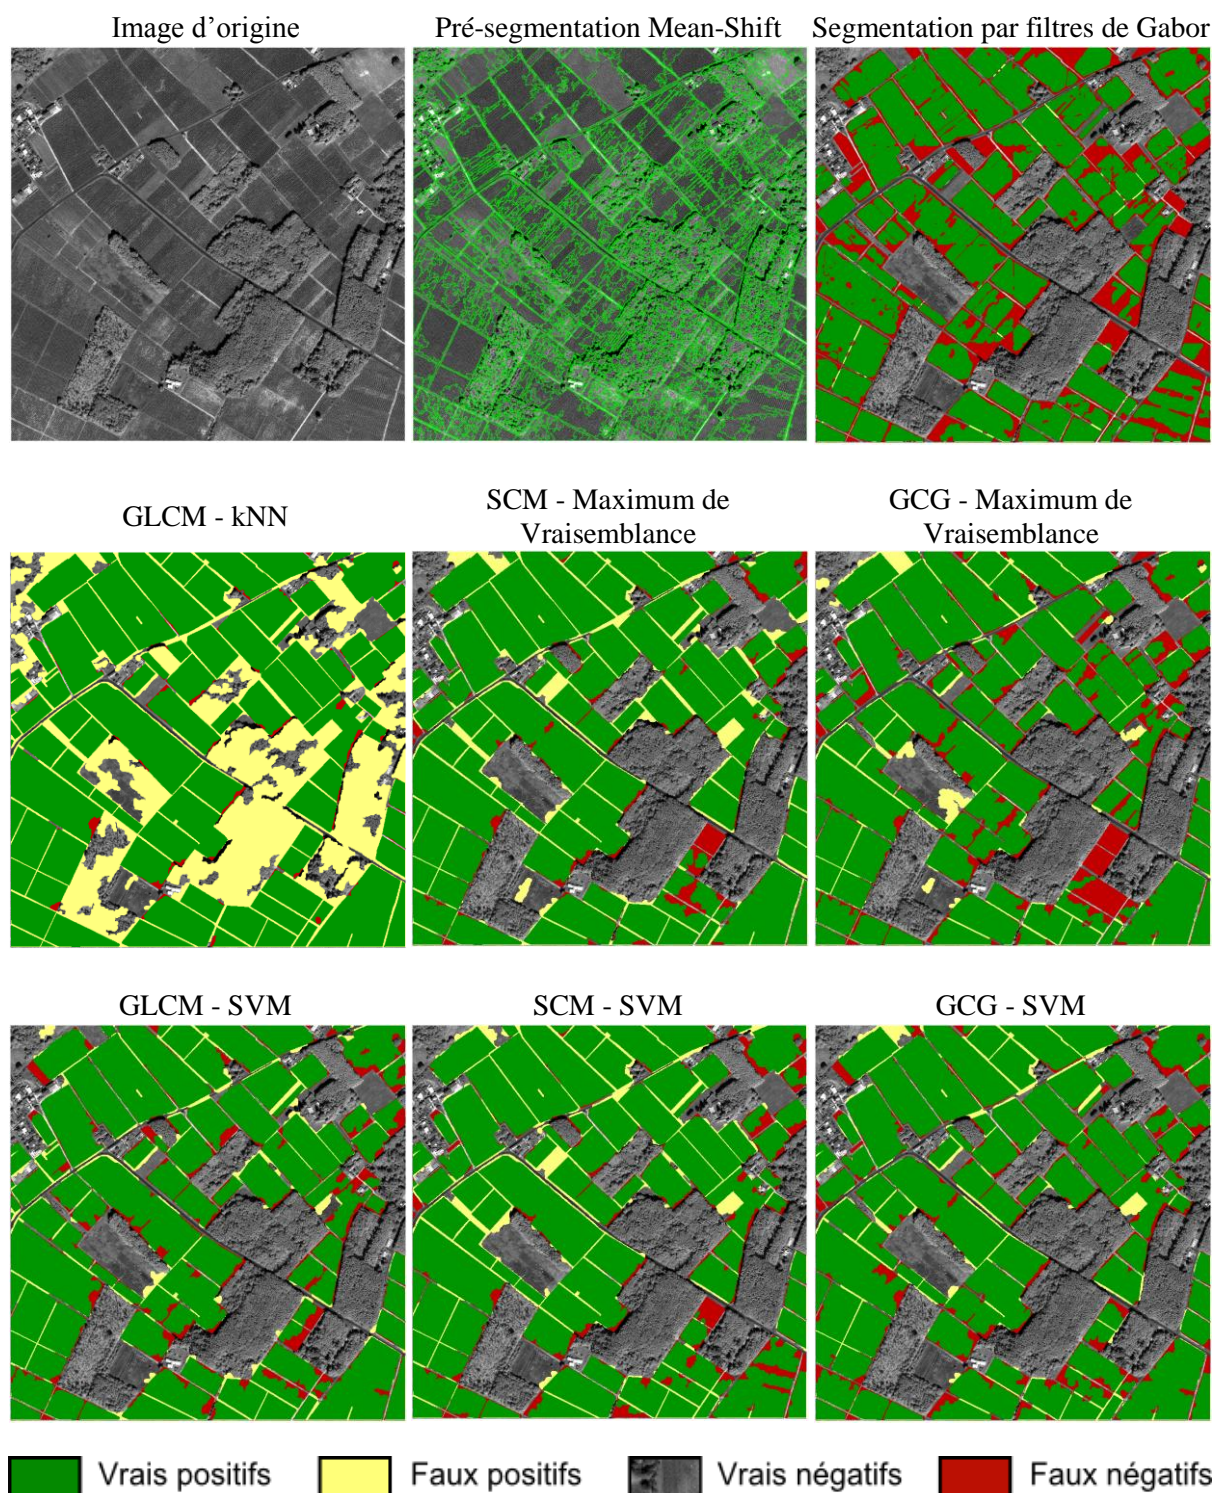


Figure 4.10 : Résultats de classification sur un extrait de l'image Pléiades du 10/09/13 en Sauternes. Les contours de couleur verte désignent les frontières de région définies par l'algorithme de Mean-Shift.



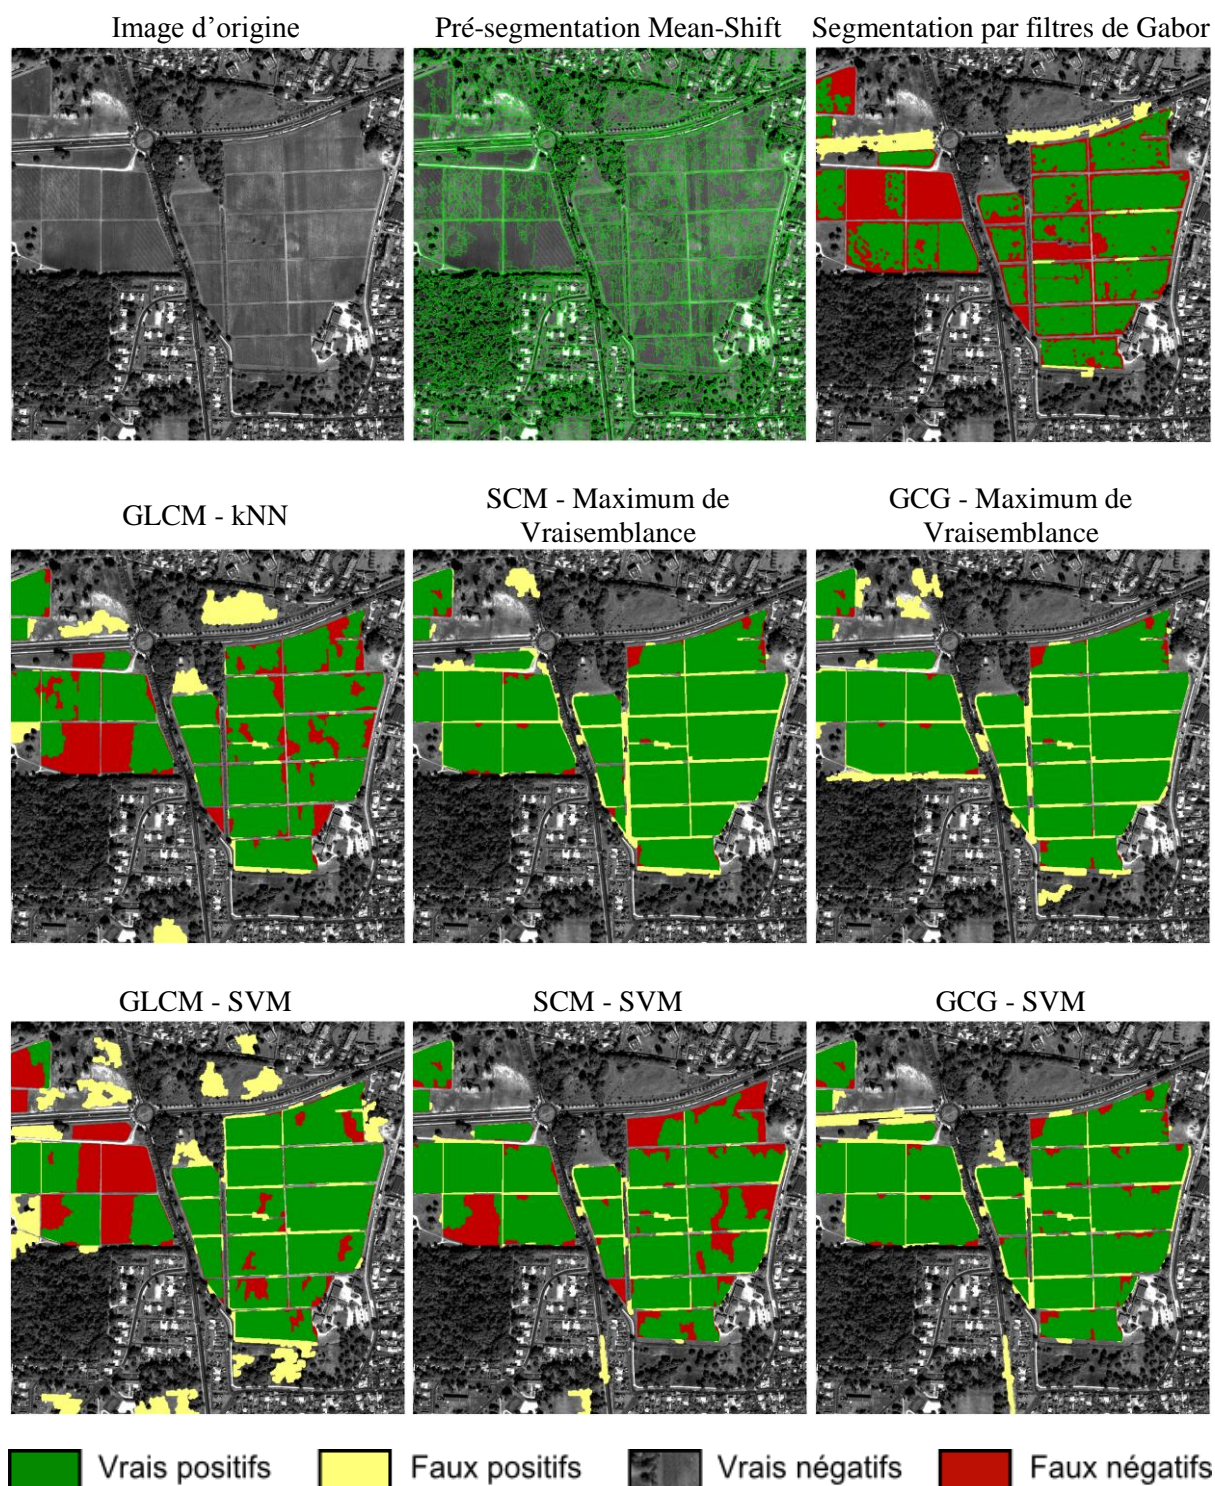


Figure 4.11 : Résultats de classification sur un extrait de l'image Pléiades du 22/08/12 en Pessac-Léognan. Les contours de couleur verte désignent les frontières de région définies par l'algorithme de Mean-Shift.

Tableau 4.2 : Précision de classification obtenue sur trois extraits d'image panchromatique Pléiades.

<b>Pléiades 01/08/13 – Saint-Emilion</b>						
Méthodes	PA (%)	UA (%)	Faux Positifs par Classe (%)			Nombre de Faux Positifs
			Bâti	Forêt	Vég. Rase	
GLCM-kNN	93.11	80.89	0.85	61.76	37.39	507 494
GLCM-SVM	90.21	92.90	0.96	1.48	97.56	159 056
SCM-ML	<b>97.11</b>	89.69	3.77	2.89	93.34	257 500
SCM-SVM	85.30	93.26	8.88	2.79	88.33	142 377
GCG-ML	93.45	94.18	4.26	9.41	86.33	133 323
GCG-SVM	92.47	95.35	6.34	2.95	90.71	104 003
Gabor	82.73	<b>99.37</b>	0.17	0.30	99.53	<b>12 008</b>
<b>Pléiades 10/09/13 – Sauternes</b>						
Méthodes	PA (%)	UA (%)	Faux Positifs par Classe (%)			Nombre de Faux Positifs
			Bâti	Forêt	Vég. Rase	
GLCM-kNN	98.44	68.86	6.30	67.13	26.57	1 073 347
GLCM-SVM	91.68	94.26	6.60	10.98	82.42	134 516
SCM-ML	<b>95.19</b>	89.77	5.87	8.16	85.97	261 219
SCM-SVM	93.06	92.04	4.48	3.91	91.61	193 919
GCG-ML	87.66	94.00	2.87	5.13	92.00	134 883
GCG-SVM	91.23	94.69	4.89	6.42	88.69	123 211
Gabor	75.45	<b>99.44</b>	0.51	0.43	99.06	<b>10 202</b>
<b>Pléiades 22/08/12 – Pessac-Léognan</b>						
Méthodes	PA(%)	UA (%)	Faux Positifs par Classe (%)			Nombre de Faux Positifs
			Bâti	Forêt	Vég. Rase	
GLCM-kNN	79.91	86.35	0.00	2.67	97.33	153 707
GLCM-SVM	77.56	75.17	6.55	11.39	82.06	311 838
SCM-ML	97.18	87.75	2.55	8.23	89.22	165 041
SCM-SVM	82.20	<b>91.65</b>	8.36	4.08	87.55	<b>91 070</b>
GCG-ML	<b>97.51</b>	85.42	2.57	21.56	75.87	202 458
GCG-SVM	95.08	87.99	23.89	5.28	70.34	157 903
Gabor	68.13	89.67	62.20	0.82	36.98	95 455

PA = Précision du producteur – UA = Précision de l'utilisateur – ML = Maximum de vraisemblance

Cependant, malgré les problèmes de sous-détection de la méthode par filtre de Gabor, cette approche s'accompagne généralement d'une précision de l'utilisateur (UA) significativement plus élevée et d'un nombre de faux positifs significativement plus bas que pour les autres méthodes. L'UA obtenue avec cette méthode est ainsi supérieure à 99% pour les images en Saint-Emilion et en Sauternes. Cela signifie qu'elle permet de cibler quasiment parfaitement les parcelles viticoles et limite la confusion avec d'autres occupations du sol. Seule la segmentation de l'image en Pessac-Léognan laisse apparaître quelques erreurs de confusion avec le réseau routier avoisinant qui engendre lui aussi une réponse fréquentielle dans le spectre de Fourier.

Pour ce qui est des approches texturales, de meilleures performances de détection sont obtenues avec les modèles multivariés. Ceux-ci sont en effet généralement associés à des PAs plus élevées et des nombres de faux positifs plus faibles que les GLCMs. Ces modèles permettent donc de mieux détecter les parcelles viticoles tout en limitant les mauvaises détections. On peut également remarquer que ce

compromis entre bonne détection et moindre erreur de détection est plus avantageux pour le modèle GCG dans le cas des images en Saint-Emilion et en Sauternes et pour le modèle SCM pour l'image en Pessac-Léognan. L'approche par GLCM atteint aussi un bon compromis dans le cas des images en Saint-Emilion et en Sauternes en utilisant le classifieur SVM. De nouveau, le rapport entre distance inter-rang et distance d'échantillonnage de l'image peut expliquer ces différences entre les trois extraits d'image analysés. Les GLCMs montrent ainsi des performances significativement plus faibles que les modèles multivariés en Pessac-Léognan et semblent donc être plus sensibles que ces modèles aux phénomènes d'atténuation de texture associés à cette image.

On peut noter que l'essentiel des faux positifs proviennent de confusions avec la classe de végétation rase. Cette classe inclut en effet les routes et chemins longeant la plupart des parcelles. Les régions définies lors de la pré-segmentation peuvent déborder de ces chemins et empiéter sur les parcelles viticoles en cas par exemple de pieds manquants ou de moindre vigueur de la vigne. Des erreurs provenant de ces régions sont donc à imputer à la méthode de pré-segmentation plutôt qu'aux approches d'analyse texturale. Il peut arriver toutefois que des zones de végétation rase partagent certaines similitudes avec les parcelles viticoles en particulier lorsque la texture est atténuée. Les erreurs de détection liées à cette classe observées en Pessac-Léognan sont probablement aussi dues à cette source de confusion.

Comme attendu, l'utilisation d'un classifieur SVM permet de limiter de manière significative le nombre de faux positifs par rapport aux classifieurs  $k$ -NN et maximum de vraisemblance. Les différences les plus flagrantes sont observées pour les GLCMs notamment dans le cas de l'image en Sauternes. Pour cette image, des confusions importantes sont apparues avec la classe de forêt en utilisant les  $k$ -NN. L'utilisation des SVMs a permis de réduire significativement cette source de confusion en divisant le nombre de faux positifs d'un facteur 10. On peut toutefois remarquer que dans l'image en Pessac-Léognan, l'utilisation des SVMs a par contre contribué à accentuer les confusions notamment avec la classe de végétation rase. Ceci confirme la limite plus floue définie entre ces deux classes par les GLCMs compte tenu de la plus forte atténuation de la texture dans cette image. Néanmoins, si les SVMs permettent de diminuer les erreurs de détection, leur utilisation s'accompagne également d'une baisse du taux de bonnes détections (PA) par rapport aux autres classifieurs, sauf dans le cas du modèle GCG sur l'image en Sauternes. Cette baisse est particulièrement marquée pour le modèle SCM dans les images en Saint-Emilion et Pessac-Léognan. Pourtant bien détectées par le classifieur par maximum de vraisemblance, les régions à l'origine de cette diminution de performances correspondent pour la plupart à des portions mitées des parcelles ou à des zones plus marquées par l'atténuation de texture. Les SVMs tendent à classer ces régions en zones bâties pour les régions mitées et en végétation rase pour les régions de texture atténuée. Ceci indique la frontière fine qui existe entre ces régions et les différentes classes de la base de données. La bonne classification de ces régions dépend donc des règles de décision du classifieur choisi.

On peut également noter que l'utilisation des SVMs et l'estimation d'un modèle pour chaque région à classer sont significativement plus avantageuses en termes de coût calculatoire que l'estimation d'un critère de vraisemblance pour chaque région. En pratique, un gain d'un facteur 3 a été observé.

## IV.5 Conclusions et perspectives

### IV.5.1 Conclusions

L'intérêt des modèles multivariés de texture sur sous-bandes d'ondelettes a été évalué dans ce chapitre dans un contexte de détection des parcelles viticoles à partir d'images panchromatiques à très haute résolution de type Pléiades. Malgré le niveau de détails atteint dans ces images, le faible rapport entre la résolution spatiale et la distance inter-rang dans les parcelles de vigne engendre des phénomènes d'atténuation de texture et d'aliasing. Ces phénomènes accentués par la géométrie d'acquisition des images compliquent la détection et la caractérisation des parcelles dans les appellations viticoles bordelaises étudiées. Les résultats obtenus en indexation et classification d'images ont démontré que les modèles multivariés Gaussien SCM et Gamma sur copule Gaussienne permettent d'atteindre une précision de classification plus élevée que des méthodes standards telles que les matrices de co-occurrence ou l'approche de segmentation basée sur les filtres de Gabor. Cette moindre sensibilité des modèles multivariés à l'atténuation de la texture confirme la capacité de ces modèles à capturer, pour la résolution spatiale étudiée, une information texturale plus riche dans l'espace transformé des ondelettes que les GLCMs dans le domaine des niveaux de gris. Bien que possédant la qualité remarquable de détecter les parcelles viticoles en limitant significativement le nombre de fausses alarmes, la méthode de segmentation par filtres de Gabor souffre toutefois d'une plus grande sensibilité à la présence de pieds manquants et à l'atténuation de la texture que les GLCMs et les modèles multivariés, de nouveau pour le contexte de résolution spatiale étudié. Lorsque le contraste entre le rang de vigne et l'inter-rang est suffisant, cette méthode reste la plus efficace et permet de détecter les parcelles sans passer par une phase d'apprentissage. Les avantages et inconvénients de ces différentes méthodes sont résumés dans le Tableau 4.3.

L'utilisation d'un classifieur SVM a permis dans la majorité des cas de diminuer de manière significative le nombre de fausses alarmes par rapport aux méthodes standards de type  $k$ -NN et maximum de vraisemblance. Cette amélioration de la précision de la classification s'accompagne néanmoins d'une diminution des taux de bonnes détections principalement dans les parcelles partiellement mitées et dans les zones de l'image plus touchées par l'atténuation de la texture. Ces observations indiquent que la frontière est fine entre ces zones de texture perturbée et les classes d'apprentissage. La qualité de classification de ces régions dépend donc plus des règles de décision du classifieur que dans les autres régions de l'image.

De manière générale, les observations réalisées au cours de cette étude démontrent que la Très Haute Résolution des capteurs satellite de type Pléiades est suffisante pour permettre de détecter et de délimiter les parcelles viticoles. Par contre, dans les appellations bordelaises analysées, cette résolution ne permet pas de discerner les rangs de plantation de manière suffisamment précise pour procéder à une caractérisation intra-parcellaire des plantations viticoles. Toute étude visant à caractériser ces parcelles pour en déduire l'orientation des rangs, la distance inter-rang ou certaines pratiques agricoles telles que la pratique d'enherbement sera donc particulièrement délicate dans ce contexte d'image. Ce genre d'applications thématiques nécessitera l'utilisation d'images de résolution plus fine telles que des images aériennes ou drones. Notons que dans certaines appellations viticoles (voir Annexe 2 pour une étude complémentaire menée en Entre-Deux-Mers), ces contraintes seront levées grâce à une densité de plantation moins élevée (distance inter-rang de 2 à 3 m). Dans la mesure du possible, l'utilisation d'images satellite pour ce type d'applications devra s'accompagner d'un



Tableau 4.3 : Avantages et inconvénients des méthodes de détection des parcelles viticoles sur des images satellite panchromatiques à très haute résolution spatiale.

	Avantages	Inconvénients
GLCM	<ul style="list-style-type: none"> <li>▪ Taux de bonnes détections élevé</li> </ul>	<ul style="list-style-type: none"> <li>▪ Taux de fausses alarmes élevé</li> <li>▪ Sensibilité à l'atténuation de la texture</li> <li>▪ Complexité de la paramétrisation</li> <li>▪ Besoin d'apprentissage</li> </ul>
Modèles multivariés	<ul style="list-style-type: none"> <li>▪ Taux de bonnes détections élevé</li> <li>▪ Taux de fausses alarmes faible</li> <li>▪ Paramétrisation simple</li> <li>▪ Moindre sensibilité à l'atténuation de la texture</li> </ul>	<ul style="list-style-type: none"> <li>▪ Sensibilité au mitage</li> <li>▪ Coût calculatoire élevé</li> <li>▪ Besoin d'apprentissage</li> </ul>
Segmentation par filtres de Gabor	<ul style="list-style-type: none"> <li>▪ Taux de fausses alarmes proche de 0%</li> <li>▪ Parcelles individualisées (une composante connexe = une parcelle)</li> <li>▪ Possibilité de caractérisation intra-parcellaire (estimation de l'orientation des rangs)</li> </ul>	<ul style="list-style-type: none"> <li>▪ Forte sensibilité au mitage</li> <li>▪ Forte sensibilité à l'atténuation de la texture</li> <li>▪ Complexité de la paramétrisation</li> </ul>

angle d'incidence le plus proche possible du nadir afin de limiter les effets d'atténuation de texture dans les parcelles.

Les conclusions dégagées ci-dessus constituent les principales contributions originales de ce chapitre. Celles-ci ont fait l'objet d'une publication dans [Regniers *et al.*, 2014a]. Nous avons en outre proposé une adaptation de la chaîne de traitement présentée au chapitre II (Figure 2.3 B) au contexte applicatif de la détection des parcelles viticoles et réalisé une étude comparative de différentes méthodes de représentation de la texture. Enfin, nous avons également analysé les limites de la très haute résolution spatiale offerte par le capteur Pléiades par rapport aux distances inter-rang dans les parcelles viticoles étudiées.

#### IV.5.2 Perspectives

Il serait dès lors intéressant de tester les modèles multivariés dans un contexte de caractérisation des parcelles viticoles dans des images de résolution spatiale suffisante pour lever les contraintes d'atténuation de texture (typiquement de l'ordre de 0,3 à 0,4 m). Les modèles multivariés ont également montré une certaine sensibilité à la présence de pieds manquants et pourraient être testés pour détecter les parcelles mitées, voire estimer le pourcentage de pieds manquants. D'autres types d'occupations de sol agricoles présentant des structures alignées (vergers, ...) pourraient également être ciblés par ce type d'outil à l'instar de [Aksoy *et al.*, 2012].

D'un point de vue méthodologique, l'algorithme du Mean-Shift utilisé lors de la pré-segmentation de l'image a montré quelques limites notamment dans les zones proches des frontières de parcelles où peuvent être créées des régions « mixtes » contenant à la fois de la vigne et d'autres couverts bordant les parcelles. Des alternatives à cette méthode de segmentation peuvent être envisagées comme la méthode des superpixels SLIC (*Simple Linear Iterative Clustering*) [Achanta *et al.*, 2012]. Des filtres

basés sur la diffusion anisotrope [[Lavialle et al., 2003](#) ; [Perona & Malik, 1990](#)] pourraient être utilisés en prétraitement afin de mieux préserver les contours des parcelles lors de la segmentation.

Enfin, les approches d'analyse texturale ont été envisagées ici de manière globale en utilisant le même modèle ou les mêmes paramètres pour toutes les classes à distinguer. Si les résultats obtenus sont satisfaisants pour l'ensemble des méthodes testées, il serait intéressant d'expérimenter une stratégie alternative dans laquelle les modèles seraient optimisés pour caractériser au mieux la classe de vigne sans se soucier des autres classes d'occupation du sol présentes dans le paysage. La mise en place d'un test d'hypothèses [[Salicru et al., 1994](#)] basé sur la loi  $\chi^2$  de distribution de la mesure de similarité entre deux modèles peut être envisagée pour déterminer si oui ou non une région appartient à la classe de vigne. Cette approche aboutirait à une classification binaire semblable aux résultats présentés dans ce travail, mais pourrait être appliquée dans n'importe quel contexte paysager.

# Chapitre V - Application à la détection de parcs ostréicoles

<b>V.1 Introduction .....</b>	<b>104</b>
<b>V.2 Site d'étude et données.....</b>	<b>106</b>
<b>V.2.1 Site d'étude et données satellite.....</b>	<b>106</b>
<b>V.2.2 Bases de données de patches de texture.....</b>	<b>107</b>
<b>V.2.3 Données de validation.....</b>	<b>109</b>
<b>V.3 Indexation par CBIR.....</b>	<b>109</b>
<b>V.3.1 Paramétrisation des matrices de co-occurrence .....</b>	<b>109</b>
<b>V.3.2 Résultats d'indexation .....</b>	<b>111</b>
<b>V.4 Résultats de classification .....</b>	<b>114</b>
<b>V.4.1 Résultats de classification .....</b>	<b>114</b>
<b>V.4.2 Résultats de validation .....</b>	<b>117</b>
<b>V.5 Conclusions et perspectives .....</b>	<b>120</b>
<b>V.5.1 Conclusions.....</b>	<b>120</b>
<b>V.5.2 Perspectives .....</b>	<b>120</b>

## V.1 Introduction

L'ostréiculture est une activité économique majeure sur la côte atlantique française et en particulier au sein du bassin d'Arcachon. Avec 850 hectares de parcs à huîtres, la production y est d'environ 9 000 à 10 000 tonnes d'huîtres creuses par an et occupe près de 320 entreprises exploitant chacune en moyenne 200 ares de parcs. Le bassin d'Arcachon est aussi le plus grand centre d'écloserie ostréicole européen et la majorité des huîtres creuses élevées en France proviennent de ce bassin. Deux modes d'élevage y sont pratiqués. La culture à plat, plus traditionnelle, consiste à disperser les huîtres directement sur l'estran (sable ou vase) dans des parcelles aménagées et clôturées (Figure 5.1 B). L'inconvénient de cette culture est que les huîtres sont plus exposées à leur prédateur et des pertes y sont souvent à déplorer. L'autre mode d'élevage, plus récent, consiste à placer les huîtres dans des poches grillagées en plastique disposées sur des tables en fer protégeant ainsi la production des dégâts de prédation. Cette dernière pratique est la plus répandue dans le bassin et se caractérise par des tables de quelques dizaines de mètres à plus d'une centaine de mètres de long disposées parallèlement les unes aux autres sur l'estran (Figure 5.1 A).

Ces dernières années, de nombreuses pressions se sont exercées sur la production ostréicole dans cette région en raison de conflits liés à l'occupation de l'espace littoral, de la moindre qualité des eaux et de l'efflorescence régulière d'espèces planctoniques toxiques obligeant la filière à cesser sporadiquement la commercialisation des huîtres. En outre, depuis 2008, des épisodes réguliers de mortalité massive des jeunes huîtres causée par un virus entraînent une diminution de la production. Ces crises écologiques touchent non seulement la production du bassin d'Arcachon, mais aussi l'ensemble des centres de production ostréicole français et internationaux. Il en résulte une désaffection de nombreux sites de production dans lesquels des friches se développent sur d'anciennes concessions abandonnées.

Ces friches constituent des zones potentielles de production (Figure 5.1 C-D) et pourraient être remises en culture. Dans l'attente d'une reprise d'activité, des démarches de conservation et de restauration de récifs sauvages ont été entrepris au sein du bassin (Figure 5.1 F). Ces récifs forment en effet des éléments structurants de l'écosystème tant en termes biologiques avec la création d'habitats que physiques par le contrôle des courants et donc de la sédimentation dans les zones protégées par ces récifs. Les huîtres étant des organismes filtreurs, ces récifs sauvages contribuent également à l'amélioration de la qualité des eaux du bassin. Bien souvent pourtant, la présence de friches sauvages peut être contre-productive. Les naissains d'huîtres tendent en effet à se fixer naturellement et massivement sur ces zones en friches. Celles-ci se développent ainsi rapidement. Ce captage non contrôlé constitue un manque à gagner pour les récoltants et exportateurs de naissains. Les friches grandissantes obligent aussi à entreprendre des opérations coûteuses de nettoyage pour la remise en culture (Figure 5.1 E). L'ostréiculture exploitant le Domaine Public Maritime contrôlé par l'état français, celui-ci finance en grande partie toutes les actions liées à ce type d'exploitation. La gestion des friches ostréicoles est donc un véritable enjeu à l'échelle nationale.

Dans ce contexte, il devient important de chercher à développer des approches permettant de caractériser spatialement les différentes typologies des couverts ostréicoles et de quantifier les stocks de production à l'échelle des bassins. La disponibilité croissante en images satellite à très haute résolution offre de nouvelles perspectives d'observation de ces couverts et donc de développement de nouvelles stratégies pour leur caractérisation. Plusieurs études récentes démontrent en effet l'intérêt de la communauté internationale pour la détection et la cartographie des cultures ostréicoles et

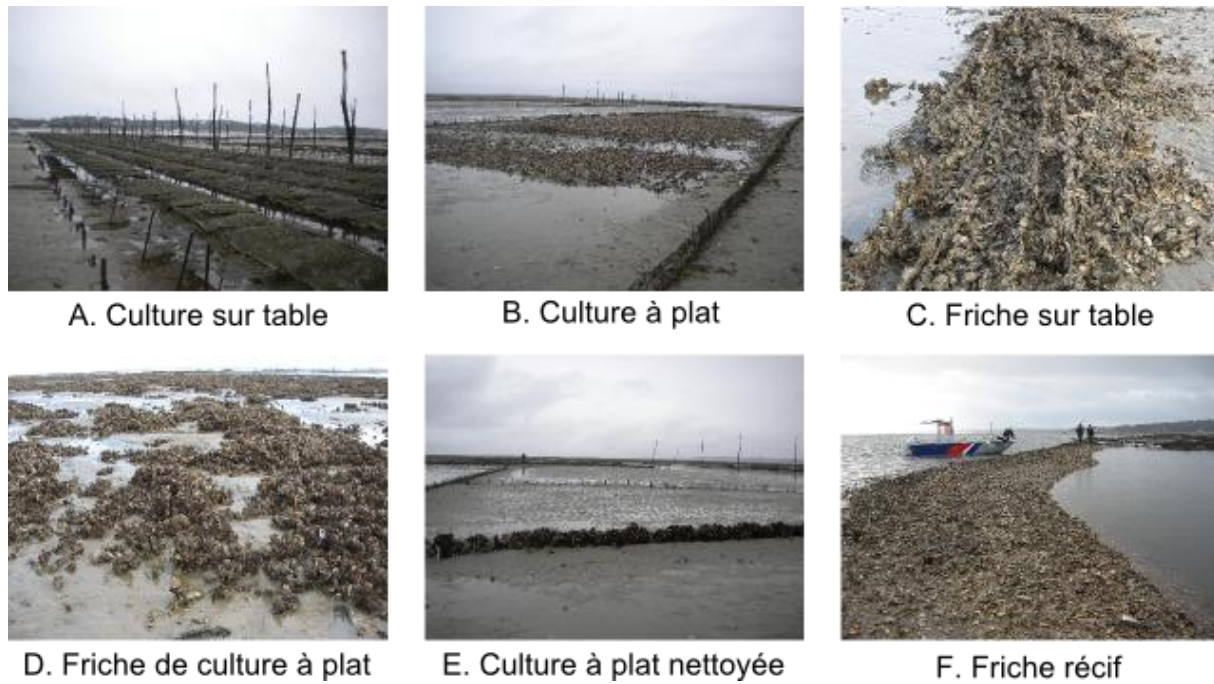


Figure 5.1 : Typologie des couverts ostréicoles.

conchylicoles à partir de données de télédétection optiques et radar [[Choe et al., 2012](#) ; [Gade et al., 2014](#) ; [Ryu et al., 2014](#)].

Une précédente étude menée dans le bassin d'Arcachon par [[Lafon et al., 2014](#)] a permis de fournir les premiers résultats de détection de parcelles ostréicoles en culture et en friche à partir d'images aériennes et d'une image WorldView-1. Cette étude se base sur des statistiques (moyenne et variance) dérivées des matrices de co-occurrence pour délimiter les contours des parcelles ostréicoles. Les contours ainsi détectés sont superposés au cadastre ostréicole et un indicateur d'exploitation (friche/culture sur table/culture à plat) est attribué à chaque polygone par un analyste expert. Si cette approche a permis de délimiter efficacement les contours des zones d'exploitation, la caractérisation des zones détectées n'est pas automatique et doit passer par une analyse par photo-interprétation. Une autre étude basée sur l'anisotropie des cultures sur table a également permis de détecter ces zones de manière efficace [[Germain et al., 2012](#)]. Celle-ci s'est appuyée sur un indice de cohérence calculé à partir des valeurs propres du tenseur de structure des gradients locaux. Toutefois, les zones de friches sur table ayant pour la plupart conservé leur anisotropie, elles sont régulièrement la source d'erreurs de détection.

Dans ce chapitre, nous proposons d'évaluer la capacité des modèles multivariés sur sous-bandes d'ondelettes à différencier par une approche supervisée les cultures sur tables des friches ostréicoles. Les résultats ainsi obtenus permettront d'affiner la caractérisation de la typologie des couverts ostréicoles. Après avoir introduit le site de l'étude et détaillé les caractéristiques des données images exploitées, les modèles multivariés et les matrices de co-occurrence sont comparés dans une analyse par indexation d'images afin d'identifier les approches d'analyse texturale les plus performantes. Dans une seconde partie, des résultats de classification supervisée sont produits et validés grâce à des données d'observations récoltées sur le terrain.




Figure 5.2 : Localisation du site d'étude. L'image principale correspond à l'image Pléiades du 25/04/13. L'encadré bleu indique l'emprise des images aériennes acquises le 26/10/11. Les zones colorées en rouge désignent la localisation des parcelles ostréicoles en culture.

## V.2 Site d'étude et données

### V.2.1 Site d'étude et données satellite

Le site d'étude est localisé dans le bassin d'Arcachon, une lagune intertidale d'une superficie d'approximativement 180 km<sup>2</sup> située le long de la côte atlantique dans le Sud-Ouest de la France (Figure 5.2). Ce milieu saumâtre riche en biodiversité résulte de la rencontre entre les eaux océaniques et les eaux douces déversées dans le bassin par la Leyre. L'écosystème est rythmé par les marées et deux fois par jour, le bassin se vide au deux tiers laissant apparaître de vastes zones d'estran dans lesquelles se situe l'essentiel des activités ostréicoles. Les parcs à huîtres sont principalement concentrés au centre du bassin sur l'île aux Oiseaux et le long des chenaux bordant les contours de cette île.

L'influence des marées sur la capacité à observer les cultures ostréicoles rend l'acquisition de données satellite sur cette zone particulièrement délicate. Il est nécessaire en effet que le passage du satellite au dessus de la zone soit synchronisé avec la marée basse et que les conditions météorologiques soient suffisamment clémentes pour limiter la présence de nuages. Ces contraintes limitent considérablement



la disponibilité d'images exploitables sur cette zone. Malgré tout, nous avons pu disposer de deux jeux de données sur ce site d'étude.

Le premier consiste en une série d'ortho-photographies aériennes acquises principalement sur la partie sud de l'île aux Oiseaux le 26/10/11 (Figure 5.2). Ces images optiques ont été acquises dans quatre bandes spectrales (bleu, vert, rouge et proche infrarouge) avec une résolution spatiale de 0,5 m. Une deuxième image panchromatique a été collectée par le capteur Pléiades le 25/04/13 dans le cadre de la Recette Thématique Utilisateurs du programme ORFEO d'accompagnement Pléiades organisé par le CNES. L'ensemble de ces données ont été fournies après correction géométrique et ortho-rectification avec une résolution radiométrique de 12 bits. Pour rendre les deux jeux de données comparables, les bandes spectrales des ortho-photographies ont tout d'abord été recombinaées afin de créer artificiellement une bande panchromatique. Comme lors des précédentes études, la résolution radiométrique des images est ramenée à 8 bits en concentrant l'histogramme autour de la dynamique principale des niveaux de gris codés sur 12 bits.

### V.2.2 Bases de données de patches de texture

Une base de données de patches de texture est créée à partir de chacun des jeux de données en repérant dans les images des zones représentatives des différentes classes à distinguer. De ces zones sont extraits des patches de dimension constante égale à 128×128 pixels. Un label relatif à sa classe d'appartenance est affecté à chacun des patches. Au vu de l'objectif poursuivi dans cette thématique, trois classes principales sont considérées : les cultures ostréicoles sur table, les cultures ostréicoles en friche et les zones d'estran (Figure 5.3).

Les deux premières classes sont caractérisées par des motifs texturaux anisotropes, les objets constituant ces motifs étant généralement plus larges dans le cas des friches sur tables que dans le cas des cultures sur tables. La dernière classe correspond à toutes les zones quotidiennement couvertes par la marée, mais non exploitées pour la culture des huîtres. Les cultures à plat et les friches associées ne sont pas prises en compte dans cette analyse en raison de leur faible contenu textural et de leur plus faible occurrence dans le paysage. La classe des friches contient par contre à la fois des friches issues de culture sur table et des friches de type récif (Figure 5.1). Cette base de données de texture est exploitée dans le cadre d'une analyse par indexation d'images pour identifier les modèles les plus performants et dans un second temps, comme base de données d'apprentissage dans une classification supervisée.

Il est utile de signaler que le motif textural caractérisant les différentes classes proposées ici n'est pas aussi homogène que lors des deux applications thématiques précédentes. Les tables ostréicoles sont généralement rassemblées par groupes étroits de 2 à 5 tables espacées de l'ordre de 1 à 2 m. La notion de parcelles est donc ici tout à fait différente que dans le cas des parcelles viticoles ou des peuplements forestiers. Plusieurs configurations d'espacement ou d'orientation peuvent ainsi se côtoyer au sein d'un même patch (Figure 5.3). L'espace entre plusieurs groupes de tables peut être également plus ou moins large incluant des « trouées » plus lisses entre les tables. Certaines tables peuvent également être vides, aucune poche d'huîtres n'y étant temporairement déposée. L'ensemble de ces observations se traduit par une plus forte variabilité texturale intra-classe, mais aussi intra-patch pour les cultures ostréicoles et dans une moindre mesure pour les friches.




Figure 5.3 : Exemples de patchs de texture représentatifs des trois classes d'intérêt issus de la base de données créée à partir de l'image Pléiades du 25/04/13.




Figure 5.4 : Localisation des zones de validation.



La sensibilité des modèles à l'orientation des textures est également analysée pour cette thématique en créant une seconde base de données de patches dans laquelle tous les patches de texture anisotrope (ici les cultures ostréicoles sur table et les cultures en friche) subissent une opération de rotation en forçant l'orientation dominante à  $0^\circ$ . Comme précédemment, cette opération est réalisée automatiquement en estimant l'orientation au moyen d'un tenseur de structure [Bigun *et al.*, 1991].

### V.2.3 Données de validation

Les données de validation utilisées dans cette étude sont issues de plusieurs campagnes d'observations *in situ* menées en 2009 et 2010 par la Direction Départementale des Territoires et de la Mer de Gironde (DDTM) ainsi que par le Bureau de Recherches Géologiques et Minières (BRGM) et la cellule de transfert GEO-Transfert [Lafon *et al.*, 2014]. Cinq secteurs de cultures ostréicoles (Figure 5.4) ont ainsi été partiellement inventoriés au cours de ces missions en renseignant pour chaque point d'observation l'état de la surface (cultivée, en friche ou estran). Chacun des points est par ailleurs géolocalisé par une mesure GPS. Un total de 288 points (51 pour les parcs cultivés, 144 pour les friches ostréicoles et 93 pour l'estran) ont ainsi été récoltés et sont utilisés pour valider les résultats de classification. Notons que l'emprise des images aériennes acquises en 2011 étant restreinte à la partie sud de l'île aux Oiseaux, seuls les résultats obtenus sur l'image Pléiades sont validés au moyen de ces données d'observation.

## V.3 Indexation par CBIR

Les réglages de paramètres relatifs à l'application des GLCMs sont d'abord présentés avant de décrire les résultats d'indexation. Les modèles multivariés sont quant à eux appliqués sur les sous-bandes d'ondelettes issues d'une transformée en ondelettes discrètes (DWT) avec une base d'ondelettes de Daubechies db4. Le nombre d'échelles de décomposition est limité à 2 en raison de la taille des patches fixée à  $128 \times 128$  pixels produisant six sous-bandes ( $2 \text{ échelles} \times 3 \text{ orientations}$ ). Les dépendances spatiales sont caractérisées en considérant des voisinages  $3 \times 3$  dans chaque sous-bande.

### V.3.1 Paramétrisation des matrices de co-occurrence

Deux paramètres sont à sélectionner : les descripteurs texturaux et la distance entre paires de sites. La taille de la fenêtre d'analyse équivaut à la dimension des patches ( $128 \times 128$ ) et le nombre de niveaux de gris considéré pour le calcul des GLCMs est maintenu à 256.

Comme dans les deux chapitres précédents, un ensemble de sept descripteurs est évalué : l'énergie, l'entropie, le contraste, la corrélation, l'homogénéité, la moyenne et la variance. Ces sept descripteurs sont déterminés pour tous les patches de la base de données en fixant la distance à 1 pixel et en moyennant les paramètres sur les quatre orientations. Une analyse en composantes principales (ACP) est ensuite réalisée pour identifier les descripteurs qui contribuent le plus aux premières composantes principales (Figure 5.5). Les descripteurs de corrélation et de moyenne apparaissent nettement comme étant ceux contribuant respectivement le plus à la deuxième et à la troisième composante principale. Pour la première composante, les descripteurs d'homogénéité et d'entropie sont sélectionnés. Ces descripteurs sont également appliqués pour les GLCMs sur ondelettes (WCFs). Les quatre descripteurs sélectionnés sont identiques à ceux choisis dans la thématique relative à la discrimination des classes d'âge de forêt (paragraphe III.3.1.1).




Figure 5.5 : Analyse en composantes principales sur les descripteurs de GLCM calculés à partir de la base de données issue de l'image Pléiades du 25/04/13. Les première et deuxième composantes sont représentées à gauche, les première et troisième à droite.




Figure 5.6 : Taux de reconnaissance moyens (ARR) obtenus avec la matrice de co-occurrence en fonction de la distance entre paires de site pour les bases de données issues des images aériennes du 26/10/11 (gauche) et de l'image Pléiades du 25/04/13 (droite).

En utilisant les quatre descripteurs sélectionnés ci-dessus et en faisant varier la distance entre paires de sites entre 1 et 5 pixels, le meilleur taux de reconnaissance moyen ARR est obtenu avec une distance de 1 pixel dans le cas des images aériennes et une distance de 5 pixels dans le cas de l'image Pléiades. Cette différence peut s'expliquer par la résolution spatiale moins fine de l'image Pléiades (0,7 m) par rapport aux images aériennes (0,5 m). La distance entre les tables ostréicoles étant dans certains cas proche de 1 m, les tables et l'espace entre ces tables tendent à se confondre dans l'image Pléiades créant des objets de dimensions plus larges pouvant justifier l'utilisation d'une distance plus grande entre paires de sites. Toutefois, la différence entre les ARR obtenus avec une distance de 5 et une distance de 1 est peu significative. Une distance de 1 pixel est donc choisie pour les deux images.

### V.3.2 Résultats d'indexation

Les résultats d'indexation sont produits en s'appuyant comme précédemment sur une procédure itérative. A chaque itération, un sous-ensemble de la base de données est créé en sélectionnant aléatoirement 25 patchs par classe. Un taux de reconnaissance moyen (ARR) est alors déterminé sur ce sous-ensemble en récupérant les distances mesurées entre chaque paire de patchs. Au bout de 100 itérations, un ARR moyen est calculé afin de comparer les méthodes. Les courbes de Rappel/Précision sont définies sur l'ensemble de la base de données.

L'analyse d'indexation est réalisée sur les mêmes méthodes d'analyse texturale que lors des deux chapitres précédents :

- La matrice de co-occurrence en concaténant dans un même vecteur les descripteurs calculés dans les quatre orientations (GLCM),
- La matrice de co-occurrence en moyennant les descripteurs sur les quatre orientations garantissant une meilleure invariance à la rotation (GLCM\_INV),
- La matrice de co-occurrence calculée sur les sous-bandes d'ondelettes en moyennant les descripteurs sur les quatre orientations (WCF),
- Le modèle Gaussien multivarié (SCM),
- Le modèle SIRV Gaussien (SIRVgauss),
- Le modèle SIRV de distribution G0 (SIRVg0),
- La Gamma multivariée sur copule Gaussienne (GCG) et
- La Gaussienne Généralisée Multivariée (MGG).

Les taux de reconnaissance ARR (Figure 5.7) ont été déterminés à partir de la base de données d'origine (BD) ainsi qu'avec la même base de données dans laquelle les patchs de texture anisotrope ont été retournés en forçant leur orientation à 0° (BDrot).

Les performances d'indexation issues des bases de données d'origine (BD) montrent une capacité de discrimination équivalente pour les GLCMs et les modèles multivariés SCM et GCG. Cela contraste avec les résultats affichés par les modèles multivariés dans les chapitres précédents pour lesquels les GLCMs étaient généralement associés à des ARR plus élevés que les approches sur ondelettes. On se trouve probablement ici dans un contexte similaire à celui observé lors de la classification des peuplements forestiers (paragraphe III.4.1). En effet, en raison de la faible dimension des parcelles ostréicoles, les patchs issus de ces parcelles exhibent une texture plus hétérogène alliant à la fois les objets formés par les tables ostréicoles et les espaces de dimensions variables entre ces tables. Les modèles multivariés par leur plus grande souplesse d'ajustement à la texture semblent être plus à même que les GLCMs de capter cette complexité de l'information texturale. Toutefois, les modèles multivariés restent plus sensibles que les GLCMs à l'orientation de la texture.

En effet, lorsque l'on analyse les résultats obtenus avec la base de données BDrot, les performances des modèles multivariés sont significativement améliorées, en particulier pour les modèles basés sur les SIRVs. Ces phénomènes également observables dans les deux autres thématiques abordées précédemment trouvent leur origine dans les stratégies de mesure de distance employées pour les modèles. La distance est en effet mesurée entre chaque paire de modèles issus de la même sous-bande de la décomposition en ondelettes. Ces distances sont ainsi spécifiques à une seule orientation et une seule échelle. Elles sont ensuite additionnées et utilisées dans le processus d'indexation. Il se peut dès




Figure 5.7 : Taux de reconnaissance moyens ARR obtenus par indexation sur les bases de données de patches de texture originales (BD - rouge) et réorientées (BDrot - bleu) des patches. Les barres d'erreur indiquent l'écart-type sur 100 itérations.

lors que la distance mesurée entre deux patches de texture anisotrope appartenant à la même classe et exhibant deux orientations différentes soit significativement plus grande qu'une distance mesurée entre un de ces deux patches et un patch d'une autre classe. Ces erreurs de classification semblent être plus marquées dans le cas des modèles SIRVs. Elles sont toutefois corrigées lorsque l'orientation des patches est identique. Or, ces phénomènes ne sont pas observés pour les GLCMs. Dans leur cas, les descripteurs issus des matrices de co-occurrence déterminées dans les quatre orientations sont soit moyennés (GLCM\_INV), soit concaténés (GLCM) dans un même vecteur. Ce vecteur unique est utilisé pour mesurer une seule distance qui contient dès lors une information non-spécifique à une seule orientation. Cette différence de stratégie explique probablement en partie la plus grande sensibilité des modèles multivariés aux orientations. Ces remarques sont valables également pour les autres thématiques.

Les bonnes performances des modèles SCM, GCG et dans une moindre mesure SIRVg0 sont confirmés par l'analyse des courbes de Rappel/Précision pour les bases de données BD et BDrot (Figure 5.8). Les courbes associées à ces modèles sont systématiquement plus proches du coin supérieur droit. Cela indique que la précision de détection se maintient à des niveaux supérieurs, même lorsque le nombre considéré d'images les plus proches augmente. On remarque également que la configuration des GLCMs sans moyenne des descripteurs (GLCM) se comporte mieux que celle avec moyenne. Cela contraste à nouveau avec les résultats des thématiques précédentes. La raison de ce comportement se trouve probablement aussi dans la plus grande hétérogénéité des textures à analyser où l'on retrouve à la fois des objets orientés (tables ostréicoles) et des textures plus lisses (estran).

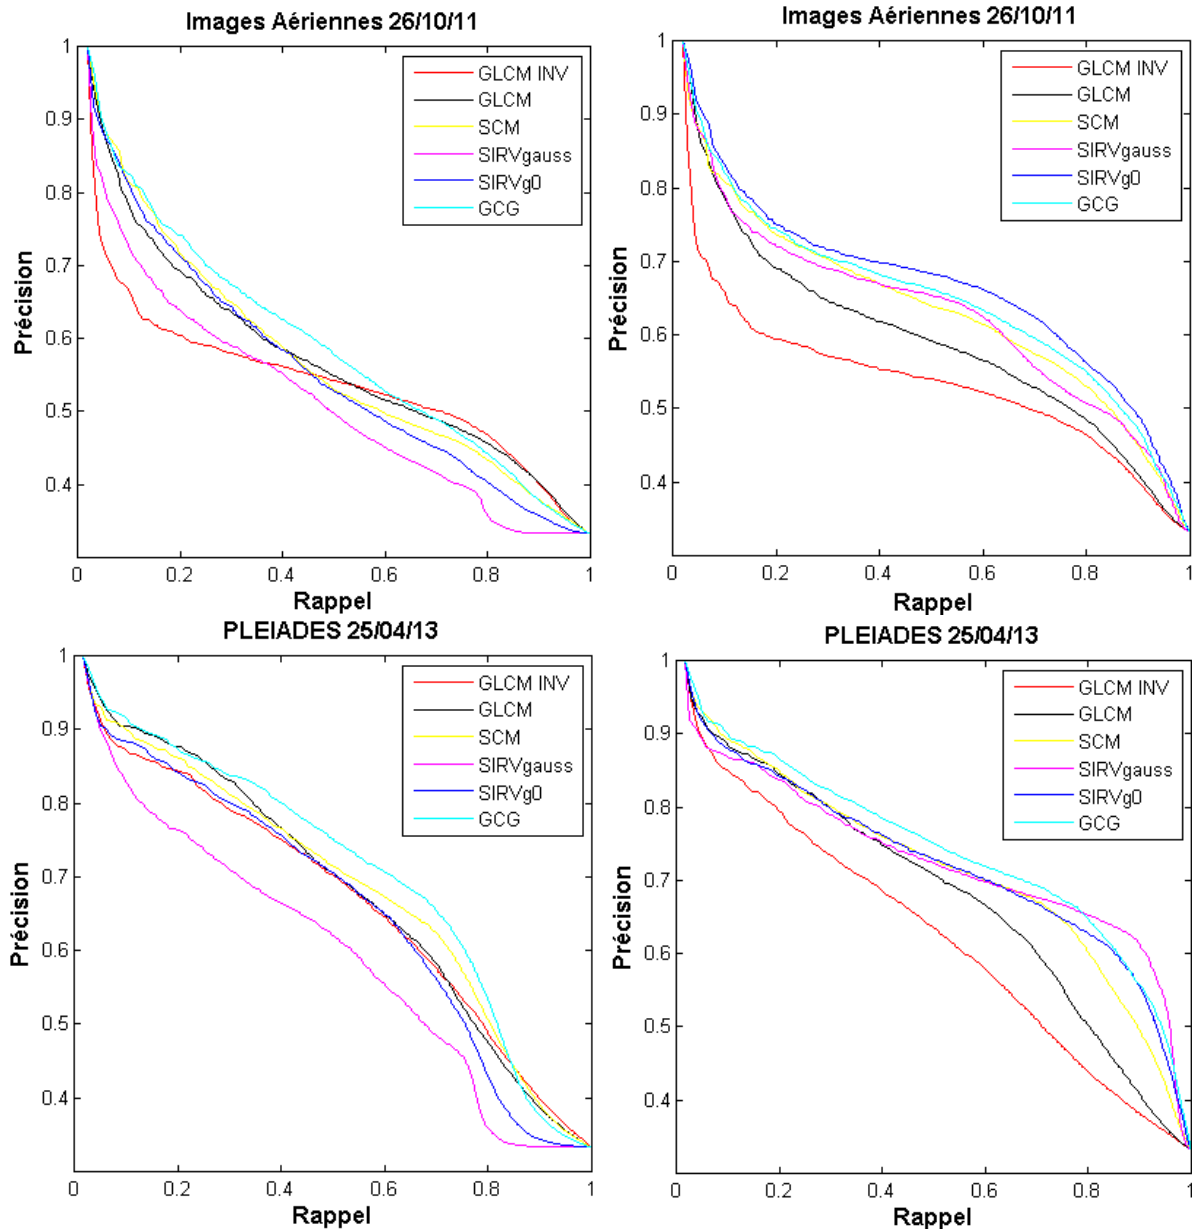


Figure 5.8 : Courbes Rappel/Précision obtenues pour les images aériennes du 26/10/11 et l'image Pléiades du 25/04/13 avec la base de données d'origine (BD – gauche) et la base de données avec rotation à  $0^\circ$  (BDrot – droite).

On peut également remarquer quelques différences entre les performances obtenues sur les images aériennes et l'image Pléiades avec pour cette dernière des courbes de Rappel/Précision généralement plus proches du coin supérieur droit pour la plupart des modèles. L'origine de ces différences pourrait provenir d'une différence de dynamique radiométrique entre les deux images causée par la présence d'algues dans le bassin d'Arcachon. Celles-ci se développent principalement au cours du printemps et se maintiennent jusqu'en automne. Elles recouvrent ainsi progressivement une partie des estrans, y compris les poches d'huîtres. Le contraste entre les tables ostréicoles et l'estran peut donc être localement modifié dans les images aériennes acquises en octobre et provoquer ainsi une moindre capacité des approches texturales à distinguer les classes considérées.

## V.4 Résultats de classification

Comme lors du chapitre IV, la stratégie de classification envisagée est une classification supervisée orientée objet pour laquelle aucune connaissance *a priori* du terrain n'est disponible (voir paragraphe II.3.1.1). Les bases de données de patches de texture sont donc ici exploitées comme données d'apprentissage. Une étape de pré-segmentation de l'image par un algorithme de Mean-Shift est appliquée sur l'image afin de déterminer les contours des régions à classer. Les résultats présentés ici ont fait l'objet d'une publication dans [Regniers *et al.*, 2014d].

Les parcelles ostréicoles étant de petite dimension, la pré-segmentation est volontairement sur-segmentée afin de préserver les contours des parcelles. Le paramètre de taille minimale des régions du Mean-Shift est ici fixé à 100 pixels. L'estimation de modèles multivariés à partir de ces régions est dès lors particulièrement délicate en raison du faible nombre d'observations de la dépendance spatiale par région. Un classifieur de type SVM n'est donc pas raisonnablement utilisable dans ces conditions. Les résultats de classification présentés ci-dessous sont tous obtenus avec un classifieur par maximum de vraisemblance pour les modèles multivariés. La méthode de classification par  $k$  plus proches voisins ( $k$ -NN) est par contre maintenue pour les GLCMs.

### V.4.1 Résultats de classification

Avant de présenter les résultats de validation obtenus sur les secteurs présentés au paragraphe V.2.3 avec les classifications réalisées sur l'image Pléiades, les résultats de classification obtenus sur le secteur de Courbey pour les deux jeux de données (images aériennes et image Pléiades) sont tout d'abord interprétés visuellement (Figure 5.9 et Figure 5.10). Cette interprétation se focalise sur les tables ostréicoles grâce à une donnée représentant les contours des tables ostréicoles dessinés à la main sur le secteur étudié. Les résultats présentés aux Figures 5.9 et 5.10 illustrent les bonnes détections de tables ostréicoles (vrais positifs en vert), les fausses alarmes (faux positifs en jaune) et les tables ostréicoles non-détectées (faux négatifs en rouge).

On peut remarquer dans un premier temps que les deux extraits d'image se distinguent nettement par les niveaux de gris qui caractérisent les tables ostréicoles. Ainsi, dans les images aériennes acquises en octobre 2011, les tables apparaissent plutôt sombres (niveaux de gris faibles) alors qu'elles sont plus claires (niveaux de gris élevés) dans l'image Pléiades. Comme mentionné précédemment, cela est probablement dû à la présence d'algues en octobre. Celles-ci s'installent y compris sur les tables et tendent à modifier la dynamique radiométrique dans les images aériennes par rapport à l'image Pléiades. Cela apparaît directement dans la pré-segmentation par Mean-Shift de l'image aérienne caractérisée par une plus forte sur-segmentation que dans l'image Pléiades. Cette sur-segmentation provoque l'apparition de petites régions dans la zone d'estran qui semblent être la source d'erreurs de classification en se confondant avec les tables ostréicoles. Les résultats de classification obtenus sur les images aériennes sont donc plus irréguliers avec de nombreuses erreurs de classification dans les zones d'estran en particulier dans les résultats obtenus avec le modèle GCG (Figure 5.9). À l'inverse, les modèles SCM et SIRVg0 semblent parvenir à limiter ces erreurs. De manière générale, il apparaît que la présence des algues est une source non-négligeable d'erreurs de détection et une acquisition d'image en dehors de leur période de développement (début printemps par exemple) est à privilégier. On peut néanmoins noter qu'un post-traitement basé sur un critère de surface minimum des



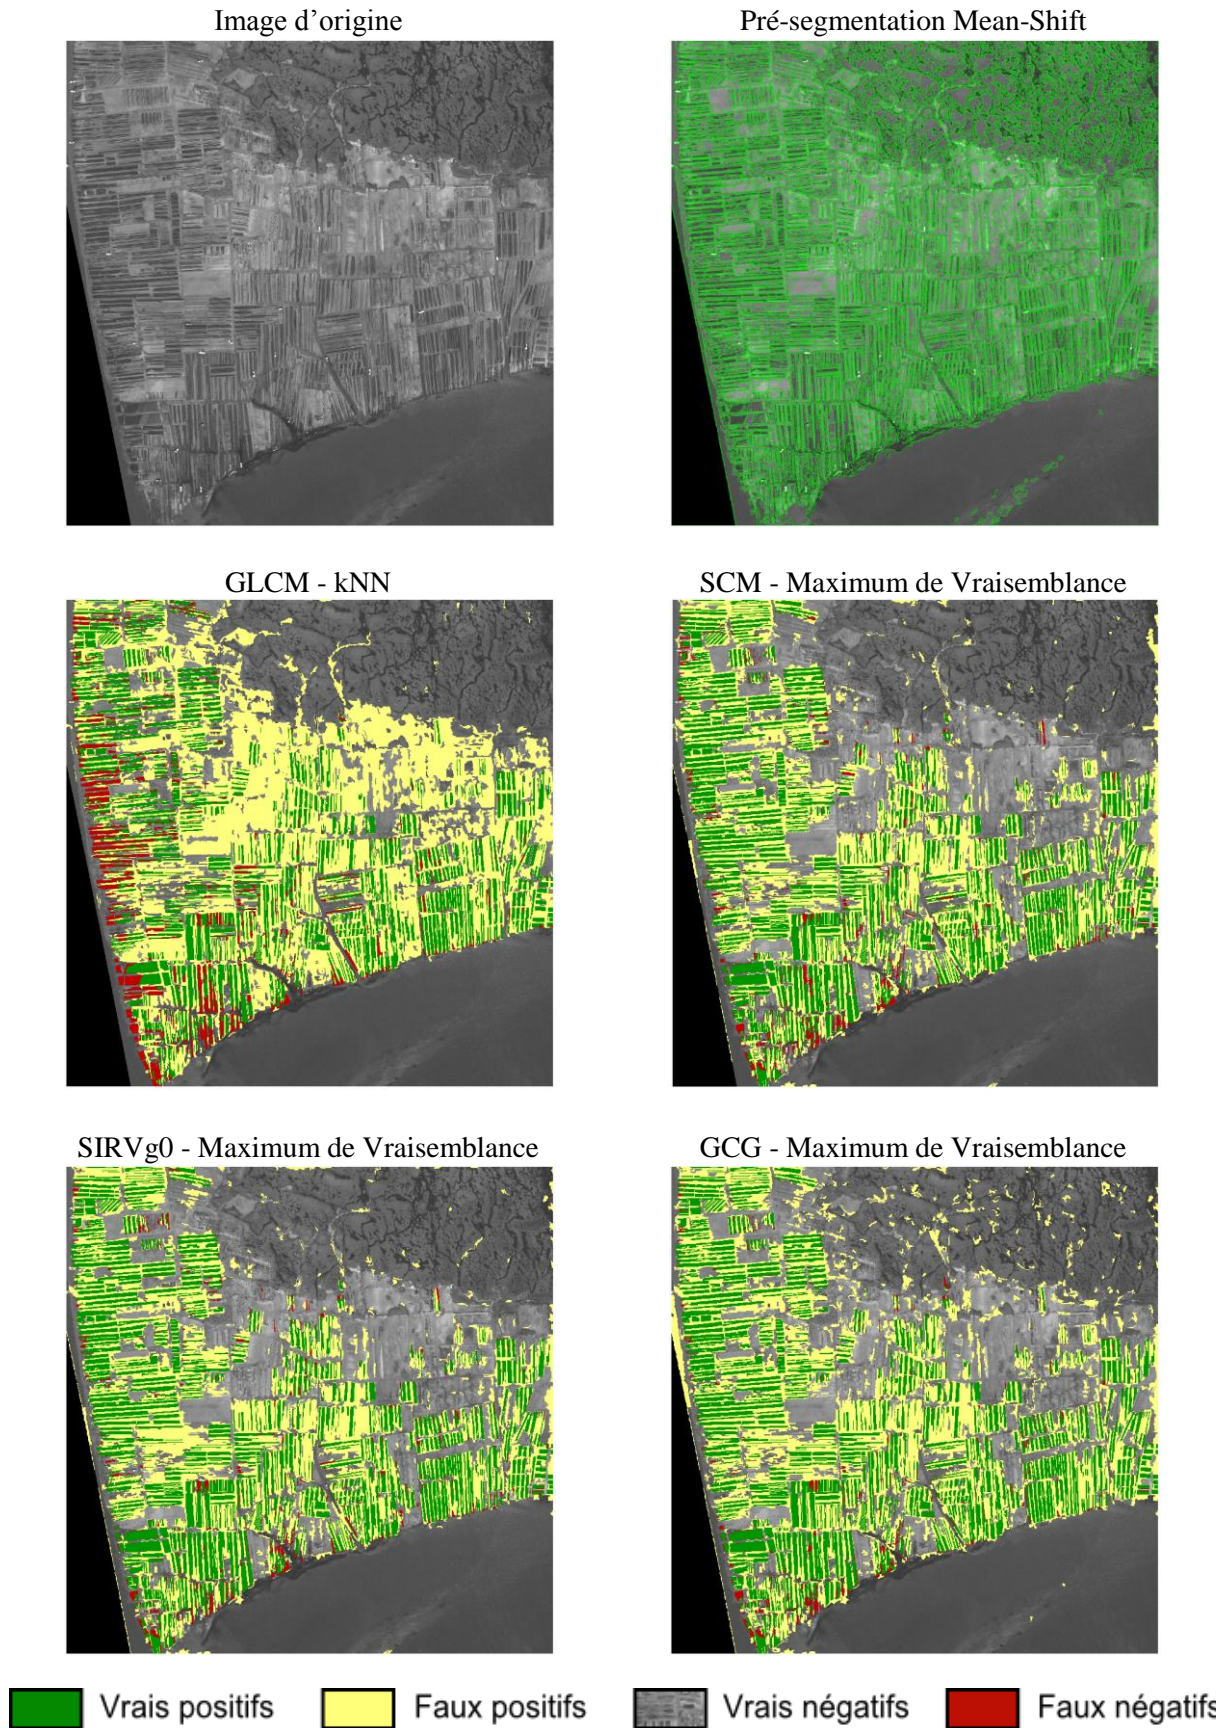


Figure 5.9 : Résultats de classification sur la zone de validation de Courbey (images aériennes du 26/10/11). Les contours en vert désignent les frontières de région définies par l'algorithme de Mean-Shift.



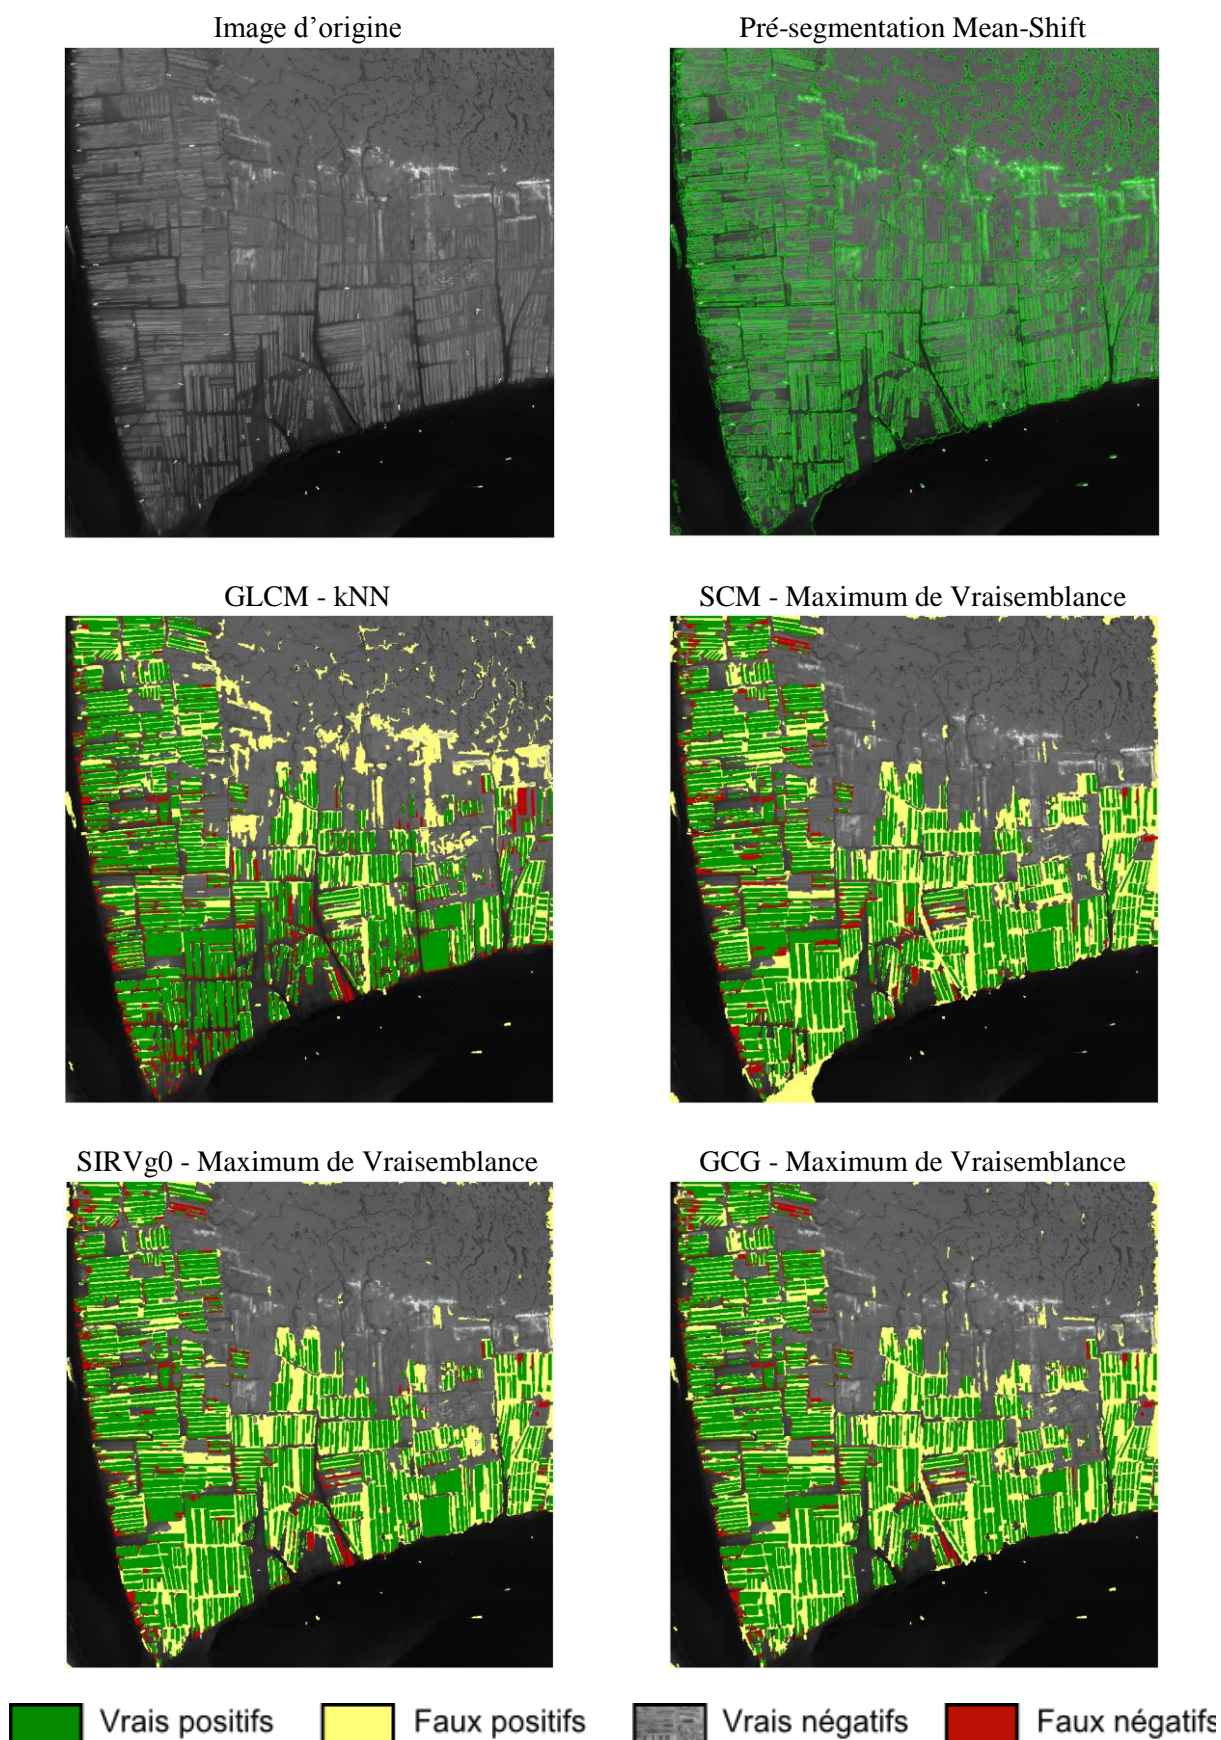


Figure 5.10 : Résultats de classification sur la zone de validation de Courbey (image Pléiades du 25/04/13). Les contours en vert désignent les frontières de région définies par l'algorithme de Mean-Shift.



composantes connexes ou sur des outils de morphologie mathématique permettrait de corriger la plupart de ces erreurs, sans toutefois éviter d'éliminer quelques régions correctement classifiées. Les GLCMs sont par contre beaucoup moins performantes que les modèles multivariés et de nombreuses erreurs de classification sont à déplorer. Une plus grande confusion est ainsi observée entre les tables ostréicoles et les zones en friche.

Les résultats obtenus sur l'image Pléiades (Figure 5.10) montrent une capacité de détection des tables ostréicoles équivalente pour les trois modèles multivariés testés (SCM, SIRVg0 et GCG). Comme pour les images aériennes, la classification avec les GLCMs montre une propension plus grande de cette approche à confondre les tables ostréicoles avec les zones en friche et les cultures à plat. Cette méthode semble être donc moins efficace que les modèles multivariés à discriminer les tables des zones en friche. Néanmoins, on peut noter que les modèles multivariés incluent aussi dans les cultures sur tables toutes les zones d'estran non cultivées séparant les tables entre elles, alors que les GLCMs délimitent de manière plus précise les contours de ces tables. Ceci peut s'expliquer par la base de données de patches d'apprentissage dans laquelle, comme cela a déjà été évoqué ultérieurement, les textures ne sont pas homogènes en raison de la petite taille des parcelles ostréicoles. Grâce à la distance de 1 pixel considérée dans le calcul des matrices de co-occurrence, les dépendances spatiales sont appréhendées de manière très locale par les GLCMs et les descripteurs issus de ces matrices semblent être moins influencés par les espaces entre les tables. À l'inverse, l'étendue des dépendances spatiales considérées en modélisation multivariée est plus large. La texture ainsi représentée lors de l'apprentissage et lors du calcul du critère de vraisemblance est donc plus influencée par ces espaces entre les tables. Il en résulte une classification qui tend à « déborder » au-delà des contours des tables. Cette qualité des GLCMs s'accompagne cependant d'une plus forte confusion entre les tables et les zones en friche, confusion nettement moins marquée pour les modèles multivariés. Une solution permettant de mieux délimiter les contours des tables au moyen des modèles multivariés serait de revoir la stratégie d'apprentissage en ne considérant plus des patches de texture incluant à la fois les tables et les espaces entre ces tables, mais des zones d'apprentissage suivant plus précisément le contour des tables.

#### V.4.2 Résultats de validation

Les résultats de classification obtenus à partir de l'image Pléiades sur cinq zones d'intérêt (Figure 5.4) sont ensuite validés au moyen des 288 points d'observation de terrain présentées au paragraphe V.2.3. Ces résultats sont résumés dans le Tableau 5.1.

Les résultats obtenus avec les GLCMs montrent que si cette approche permet d'atteindre le pourcentage le plus élevé de bonnes détections des tables ostréicoles, elle s'accompagne également d'une confusion importante avec les friches ostréicoles (67 % des friches sont classées en zones cultivées). Ce constat confirme les résultats obtenus dans l'étude menée par [\[Lafon et al., 2014\]](#). Dans cette étude, des descripteurs dérivés des GLCMs avaient permis de détecter efficacement les cultures sur table et les friches, mais une analyse d'expert avait été nécessaire pour distinguer les friches des cultures sur table parmi les zones détectées.

Par contre, les résultats obtenus avec les modèles multivariés affichent un taux de confusion entre friches et zones cultivées nettement plus faible que pour les GLCMs. Ces outils permettent donc de distinguer plus efficacement les deux typologies de couverts ostréicoles étudiées. Le meilleur compromis entre taux de bonnes détections des parcs ostréicoles (75%) et faible taux de confusion

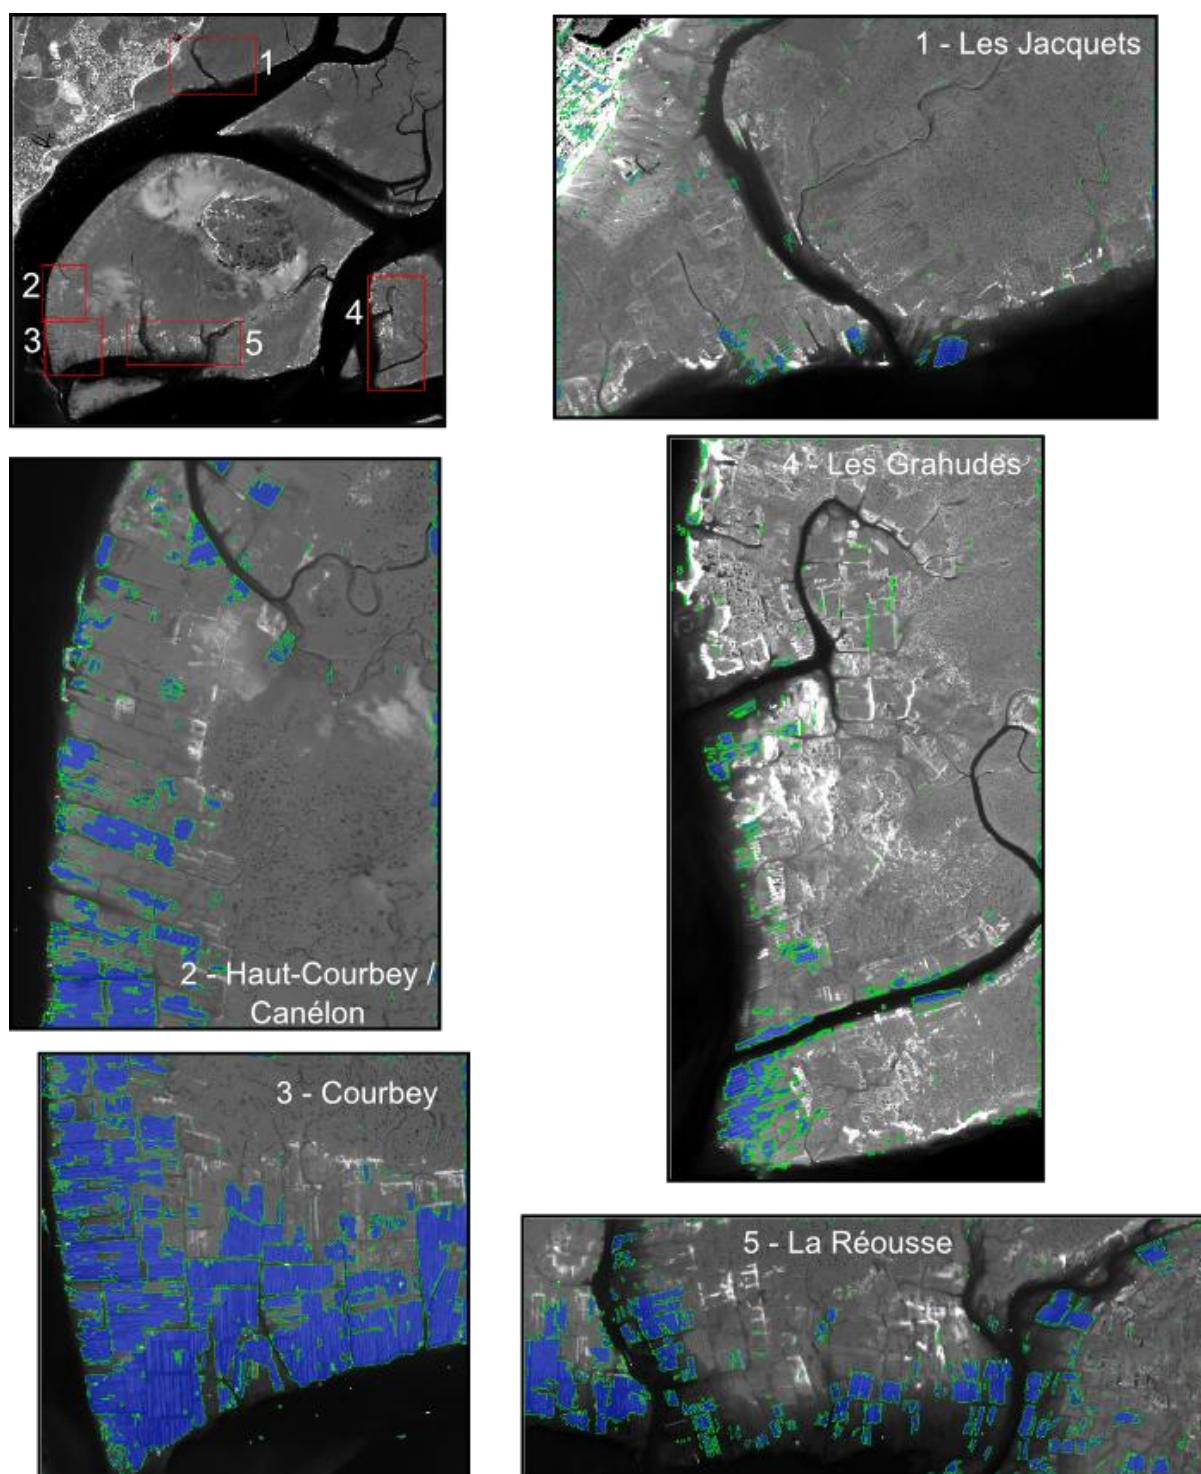


Figure 5.11 : Résultats de classification sur les cinq zones de validation obtenus avec le modèle SIRVg0. Les polygones bleus correspondent aux tables ostréicoles détectées.

Tableau 5.1 : Résultats de validation

	GLCM	SCM	SIRVg0	GCG
Pourcentage total de bonnes classifications	48 %	65 %	<b>70 %</b>	66 %
Pourcentage de cultures sur tables bien détectées	<b>88 %</b>	68 %	75 %	71 %
Pourcentage de friches ostréicoles classées en cultures sur table	67 %	<b>6 %</b>	10 %	13 %




Figure 5.12 : Exemples d'erreurs de classification. Les contours de couleur verte désignent les polygones classifiés en culture sur table.

entre parcs cultivés et friche (10%) est atteint avec le modèle SIRVg0. Une étude plus approfondie des résultats obtenus avec ce modèle (Figure 5.11) permet d'identifier plusieurs sources de confusion. Ainsi, des confusions entre les tables ostréicoles et l'estran se produisent principalement pour les tables partiellement immergées (faible contraste entre les tables et l'estran) et sur les tables partiellement vides sur lesquelles aucune poche d'huîtres n'est temporairement entreposée (Figure 5.12 A-B). Par ailleurs, dans un nombre de cas significatif (10 %), les friches ostréicoles sont mal classifiées en parcelles ostréicoles cultivées. Ces erreurs de classification sont liées à la présence de friches ostréicoles denses non-structurées (Figure 5.12 C) ou à des friches récentes affichant encore

l'orientation des anciennes tables (Figure 5.12 D). On trouve aussi quelques erreurs liées aux bordures de friches se développant sur d'anciennes cultures à plat, celles-ci étant mal prises en compte dans la base de données d'apprentissage (Figure 5.12 E).

## V.5 Conclusions et perspectives

### V.5.1 Conclusions

La capacité des modèles multivariés à distinguer les parcs ostréicoles cultivés des friches ostréicoles a été évaluée dans ce chapitre à partir d'une image panchromatique Pléiades et d'images aériennes. En comparaison avec les matrices de co-occurrence, ces modèles ont permis de détecter les cultures d'huîtres sur tables de manière plus satisfaisante en limitant les confusions avec les zones en friches. La validation des résultats de classification obtenus ont ainsi démontré des performances de détection satisfaisantes pour trois des modèles multivariés testés : le modèle Gaussien SCM, le modèle SIRV de distribution G0 et le modèle Gamma sur copule Gaussienne. Le meilleur compromis entre une bonne détection des parcs ostréicoles cultivés et une faible confusion avec les friches sur table est atteint avec le modèle SIRVg0. Il s'est toutefois avéré que les modèles multivariés ne parviennent pas à délimiter les contours des parcelles ostréicoles de manière précise en incluant fréquemment les zones d'estran situés entre les tables dans les zones classifiées en parcelles cultivées. Ce défaut de détection est moins marqué dans les résultats obtenus avec les GLCMs, mais ceux-ci s'accompagnent d'autres erreurs de détection non-négligeables. Cette tendance à « déborder » des contours des parcelles trouve probablement son origine dans l'hétérogénéité texturale des patchs d'apprentissage qui intègrent à la fois les tables et les espaces entre ces tables.

Les conclusions présentées ci-dessus constituent les principales contributions de ce chapitre et ont fait l'objet d'une publication dans [Regniers *et al.*, 2014d]. Nous avons en outre proposé une adaptation de la chaîne de traitement présentée au chapitre II (Figure 2.3 B) au contexte applicatif de la détection des parcs ostréicoles et réalisé une étude comparative de différentes méthodes de représentation de la texture. Enfin, nous avons également démontré l'adéquation de la très haute résolution spatiale offerte par le capteur Pléiades pour ce type d'application de cartographie d'occupations du sol.

### V.5.2 Perspectives

Une meilleure stratégie de définition des zones d'apprentissage pour la classe des parcelles cultivées permettrait potentiellement de mieux cibler la texture propre aux tables ostréicoles et ainsi d'éviter des erreurs de classification observées dans les résultats.

Une autre source d'amélioration concerne, comme dans le chapitre IV, l'algorithme du Mean-Shift utilisé lors de la pré-segmentation de l'image. Pour préserver les contours des parcelles, il est en effet nécessaire de privilégier une forte sur-segmentation de l'image. Le nombre de régions ainsi définies est dès lors particulièrement élevé ce qui peut être pénalisant en termes de temps de calcul lors de l'estimation du critère de vraisemblance pour la classification. Comme pour la vigne, des filtres basés sur la diffusion anisotrope pourraient être appliqués avant la segmentation afin de lisser l'image tout en conservant le contour des parcelles [Lavialle *et al.*, 2003 ; Perona & Malik, 1990]. Des alternatives à la méthode de segmentation par Mean-Shift peuvent être également proposées comme la méthode des superpixels SLIC (*Simple Linear Iterative Clustering*) [Achanta *et al.*, 2012].



La stratégie de paramétrisation des approches d'analyse texturale proposée ici est une stratégie globale consistant à considérer le même réglage de paramètres ou le même type de modèle pour toutes les classes à distinguer. Si les résultats présentés apportent une qualité de détection satisfaisante, il pourrait être intéressant d'expérimenter une autre stratégie dans laquelle les modèles seraient choisis pour caractériser au mieux chacune des classes individuellement. Un indicateur d'adéquation des modèles (*Goodness-of-Fit*) serait ensuite employé pour déterminer l'appartenance d'une région à l'une ou l'autre classe.

Par ailleurs, de nombreuses autres perspectives ont été envisagées pour cette thématique et ont fait l'objet d'une demande de financement TOSCA dans le cadre du projet COQUILLE à l'initiative de la cellule de transfert GEO-Transfert et en collaboration avec le laboratoire IMS. Ainsi, malgré les bonnes performances des modèles multivariés à détecter les tables ostréicoles, un nombre significatif de friches sont mal classifiées en parcelles cultivées. Ces confusions sont souvent associées avec des friches ostréicoles denses et non-structurées (friches récifs par exemple) ainsi qu'avec des structures caractéristiques des cultures à plat en activité ou en friche. En réalité, toute la diversité des typologies de couverts ostréicoles n'a pas été prise en compte dans cette étude. Une classe spécifique aux friches récifs ou aux cultures à plat n'a ainsi pas été incluse dans la base de données d'apprentissage. D'un point de vue méthodologique, l'objectif du projet COQUILLE vise à repérer l'ensemble des typologies de couverts en couplant deux indicateurs majeurs que sont la texture et la rugosité déduites respectivement de données de télédétection optique et SAR à très haute résolution. Les cultures à plat et les friches denses non-structurées telles que les friches récifs n'arborent en effet pas de motifs texturaux spécifiques. Par contre, la présence dense d'huîtres en surface dans les cultures à plat actives ou en friche est souvent associée à une réponse de rétrodiffusion radar élevée par rapport à leur environnement sédimentaire [[Choe et al., 2012](#) ; [Gade et al., 2014](#)]. Des indices de rugosité issus des données SAR pourraient donc être définis pour distinguer ces typologies de couverts des autres types de cultures plus texturées.

En outre, il est prévu dans le cadre du projet COQUILLE de tester la robustesse des méthodes de détection proposées en les appliquant dans d'autres régions ostréicoles françaises (Marennes-Oléron, baie de Bourgneuf et île de Ré). Des données Pléiades acquises dans le cadre de la Recette Thématique Utilisateurs sont déjà disponibles sur ces régions. De manière plus prospective, ces études complémentaires permettront aussi d'aborder la détection des couverts d'huîtres sur des surfaces rocheuses, une autre typologie de couvert absente du bassin d'Arcachon.



# Conclusions

Dans ce travail de thèse, nous nous sommes attachés à évaluer le potentiel des modèles multivariés, sur la base d'une décomposition en ondelettes, à représenter efficacement la texture dans un contexte de classification d'images de télédétection optique à très haute résolution. L'analyse de l'état de l'art dans le domaine, présentée dans le premier chapitre de ce mémoire, illustre en effet les avantages de cette représentation probabiliste à la fois par son analyse multi-échelles et multi-orientations de la texture et par sa capacité à résumer le contenu textural des images sous une forme compacte et fidèle. De telles approches sont encore peu étudiées en télédétection optique et ce travail de thèse constitue l'une des premières contributions à l'utilisation de ces modèles dans ce contexte particulier.

Après avoir détaillé dans un deuxième chapitre l'ensemble des outils utilisés pour évaluer ces modèles, trois thématiques d'application pour lesquelles nous disposons de plusieurs images aériennes et satellite (capteurs Pléiades et GeoEYE) ont été proposées. Chacune de ces thématiques a fait l'objet d'un chapitre distinct : la différenciation de classes d'âge de peuplements de pins maritimes dans la forêt des Landes de Gascogne (chapitre III), la détection de parcelles viticoles dans des appellations bordelaises (chapitre IV) et la détection de cultures ostréicoles sur tables dans le bassin d'Arcachon (chapitre V). Pour chacune de ces thématiques, une base de données de patches de texture a été créée à partir des images disponibles. Ces bases de données ont permis d'évaluer les performances de modèles multivariés dans le cadre d'une analyse d'indexation d'images et ont ensuite été exploitées comme bases de données d'apprentissage dans une procédure de classification supervisée. Ces performances sont comparées avec celles obtenues par les matrices de co-occurrence de niveaux de gris (GLCMs), considérées comme une méthode de référence d'analyse de texture en télédétection optique. Une comparaison est également menée avec une méthode basée sur les filtres de Gabor dans le cas des parcelles viticoles.

Dans les trois thématiques explorées, les modèles multivariés ont révélé des capacités remarquables de représentation de la texture. En effet, pour chaque application, au moins un des modèles multivariés testés a démontré des performances de classification supérieures aux GLCMs. Ces résultats confirment l'intérêt de la représentation multi-échelles et multi-orientations de la texture dans l'espace transformé en ondelettes et la pertinence de la modélisation multivariée des coefficients d'ondelettes issus de cette décomposition. Les modèles identifiés comme les plus performants diffèrent toutefois d'une thématique à l'autre. Ainsi, le modèle SIRV Gaussien affiche les performances de classification les plus élevées dans la thématique forêt alors que les modèles Gaussien SCM et Gamma sur copule Gaussienne (et le modèle SIRV G0 dans une moindre mesure) sont plus efficaces pour détecter les parcelles viticoles et les parcs ostréicoles. Ceci confirme que chaque thématique abordée possède ses propres spécificités en termes de texture, de taille des objets et d'anisotropie. Le type de modèle utilisé doit donc s'adapter aux spécificités de chaque problématique abordée.

La procédure d'indexation employée pour chaque thématique semble être une bonne approche pour identifier les configurations de modèles les plus performantes. Les modèles identifiés par cette procédure ont en effet systématiquement montré de bonnes performances lorsqu'ils ont été appliqués en classification supervisée. Il faut cependant rester prudent lors de l'interprétation des résultats d'indexation. Dans ce contexte d'analyse, les GLCMs ont ainsi souvent montré des performances supérieures aux modèles multivariés alors qu'elles ne parvenaient plus à les surpasser en classification. L'indexation repose en effet sur une base de données de patches de textures homogènes tandis que les régions à classer peuvent contenir des motifs texturaux plus hétérogènes. Ce fût par exemple le cas

dans la classification de la forêt réalisée à partir d'une donnée de référence d'âge de peuplements. Les GLCMs se sont montrées plus sensibles à cette hétérogénéité que les modèles multivariés plus à même de s'adapter à la complexité des motifs texturaux. Ces phénomènes ont également été observés dans la détection des parcs ostréicoles où l'hétérogénéité des textures est directement présente dans la base de données de patches en raison de la petite taille des parcs ostréicoles. Les résultats d'indexation sur les parcs à huîtres ont montré une capacité équivalente de reconnaissance des patches entre les GLCMs et les modèles multivariés alors que les GLCMs étaient plus performantes dans les autres thématiques.

L'orientation des textures s'est également révélée une source importante de différences de comportement entre les GLCMs et les modèles multivariés, les premiers étant plus invariants à la rotation que les derniers. Cette différence est particulièrement visible dans les résultats d'indexation et s'explique en grande partie par la stratégie de mesure de distance employée. Contrairement aux GLCMs pour lesquelles les descripteurs spécifiques à chaque orientation sont concaténés ou moyennés dans un même vecteur utilisé pour mesurer les distances, les similarités entre modèles multivariés sont mesurées entre les modèles obtenus pour chaque paire de sous-bandes de la décomposition en ondelettes et ensuite additionnées. Il se peut dès lors que la distance entre deux patches de texture différant uniquement par leur orientation soit plus grande qu'une distance mesurée entre un de ces deux patches et un patch issu d'une autre classe. Cependant, cette sensibilité des modèles multivariés à l'orientation a pu être compensée lors la classification supervisée. Les règles de décision des classifieurs utilisés se basent en effet sur un critère de distance ( $k$ -NN et SVM) ou de maximum de vraisemblance entre la région à classifier et le(s) patch(s) ou région(s) d'apprentissage le(s) plus proche(s). Il suffit par conséquent de disposer d'une variabilité suffisante d'orientations dans la base de données d'apprentissage pour s'assurer que chaque région à classifier trouve dans cette base une texture similaire en termes de contenu et d'orientation. Cela a par exemple été le cas pour la détection des parcs à huîtres et des parcelles viticoles. Par contre, la base de données de référence utilisée pour classifier les âges de peuplements forestiers n'est pas suffisamment exhaustive en termes d'orientations des textures et le manque d'invariance à la rotation des modèles multivariés a été la source d'erreurs de classification dans ce cas. Le nombre d'erreurs ont toutefois pu être réduit grâce à l'utilisation d'un classifieur basé sur les SVMs.

Le choix du classifieur s'est effectivement montré important pour la qualité des résultats de classification, les SVMs s'étant révélés plus performants que les classifieurs par maximum de vraisemblance et  $k$  plus proches voisins en minimisant le nombre d'erreurs de classification. Lors de la détection des parcelles viticoles, l'utilisation des SVMs s'est cependant accompagnée d'une augmentation de la sensibilité des modèles aux pieds manquants et à l'atténuation de la texture. Le coût calculatoire des SVMs est aussi généralement moindre que celui engendré par l'estimation d'un critère de vraisemblance. Notons toutefois que lorsque la taille des régions est faible, des problèmes d'estimation des paramètres peuvent se produire, comme ce fût le cas lors de la détection des parcs ostréicoles. Dans ce contexte, la classification par maximum de vraisemblance a montré de façon expérimentale une qualité de classification satisfaisante.

Enfin, l'ensemble des travaux présentés dans ce mémoire ont fait l'objet de trois communications dans des conférences internationales ([[Regniers et al., 2013](#) ; [Regniers et al., 2014c](#) ; [Regniers et al., 2014d](#)]) et de deux publications dans des revues scientifiques ([[Regniers et al., 2014a](#) ; [Regniers et al., 2014b](#)]).



# Perspectives

Les perspectives générales présentées ici concernent principalement la méthodologie employée dans le cadre de cette thèse et viennent compléter les perspectives thématiques proposées dans les conclusions des chapitres III, IV et V.

Ce travail de thèse constitue une première tentative d'exploration des potentialités des modèles multivariés appliqués sur les sous-bandes d'une décomposition en ondelettes pour la classification des images de télédétection optique. Le schéma général proposé pour toutes les thématiques abordées s'appuie sur une décomposition en ondelettes discrète (DWT) avec un filtre de Daubechies défini par quatre moments nuls (db4). Ce choix est motivé par la capacité de la DWT à fournir des sous-bandes indépendantes et par le compromis que le filtre db4 autorise entre la dispersion du filtre dans l'espace et sa localisation en fréquence. Néanmoins, comme cela a été évoqué dans le premier chapitre, bon nombre d'**autres configurations de décomposition en ondelettes** ont été proposées dans la littérature et mériteraient d'être explorées dans les contextes applicatifs de cette thèse. L'utilisation de frames d'ondelettes non-décimées avec un filtre db4 proposée par [Unser, 1995] et testée par exemple par [Choy & Tong, 2010 ; Do & Vetterli, 2002] ont montré la supériorité de cette approche par rapport à la DWT. La décomposition en ondelettes complexe par arbre dual (DT-CWT) proposée par [Selesnik *et al.*, 2005] et utilisée entre autres par [Kwitt & Uhl, 2008] présente certains avantages par rapport à la DWT en permettant une plus grande sélectivité directionnelle. Il en est de même avec la décomposition en pyramides orientées [Portilla & Simoncelli, 2000] exploitée pour modéliser la texture dans [Lasmar & Berthoumieu, 2010]. Si ces approches permettent de prendre en considération un plus grand nombre de directionnalité dans l'analyse des textures, elles s'accompagnent également d'un coût calculatoire plus élevé avec un plus grand nombre de sous-bandes à modéliser. Enfin, d'autres filtres de la famille Daubechies pourraient être testés afin d'évaluer la réponse des modèles à une localisation plus fine en fréquence (db2) ou à une dispersion du filtre plus grande dans l'espace (db8).

Lors de la classification de l'âge des peuplements forestiers, il est apparu que chaque classe d'âge considérée présentait ses propres spécificités en termes de tailles des objets, d'anisotropie des textures et de réponse spectrale. La stratégie de représentation de la texture employée s'est attachée à définir un seul et unique modèle avec le même nombre d'échelles de décomposition pour différencier l'ensemble des classes. L'avantage de cette stratégie est qu'elle ne nécessite de déterminer qu'une seule mesure de similarité pour comparer les textures à classifier. Par contre, le modèle utilisé et le nombre d'échelles de décomposition choisis ne sont peut-être pas optimaux pour représenter les classes de textures prises individuellement. Si les résultats obtenus avec cette stratégie de modélisation globale ont été satisfaisants, il serait intéressant d'expérimenter une **approche multi-modèles** dans laquelle un modèle multivarié serait sélectionné afin de représenter au mieux la texture caractéristique de chacune des classes. Le modèle choisi pourrait être ainsi différent pour chacune des classes. La sélection pourrait se baser sur un test d'adéquation (*Goodness-of-Fit*) de type  $\chi^2$  en pondérant toutefois le résultat du test par un critère d'information bayésienne (BIC – *Bayesian Information Criterion*) afin de tenir compte de la complexité de chaque modèle. La phase de classification serait toutefois plus couteuse en temps de calcul car elle nécessiterait de déterminer un critère de vraisemblance ou une mesure de similarité pour le modèle défini pour chacune des classes.

De manière similaire, une **approche orientée détection** pourrait être envisagée dans le cas des thématiques sur les parcelles viticoles ou les parcs ostréicoles en sélectionnant un seul modèle choisi

pour représenter au mieux la classe à détecter. La classification obtenue serait alors une classification binaire contenant une classe correspondant à l'occupation du sol ciblée et une classe de rejet. Un test d'hypothèse comme celui proposé dans [Salicru *et al.*, 1994] et basé sur la loi  $\chi^2$  de distribution de la mesure de similarité entre deux modèles pourrait être envisagé comme règle de décision.

L'ajout de paramètres de modélisation relatifs à la dépendance couleur en complément des modèles de dépendance spatiale (**fusion spectral/spatial**) a été investigué uniquement dans le cas de la thématique forêt. L'utilisation de la dépendance couleur a permis d'améliorer les résultats de classification dans cette thématique pour la plupart des modèles multivariés testés. Cette information complémentaire à l'analyse des dépendances spatiales mérite d'être approfondie. Il serait intéressant par exemple de comparer l'apport de cette modélisation à l'utilisation des bandes spectrales par la détermination d'une moyenne et/ou d'un écart-type de niveaux de gris par peuplement forestier ou par région dans les autres thématiques. De plus, le même modèle a été utilisé à la fois pour décrire les dépendances spatiales et les dépendances couleurs. Le choix de modèles distincts pour représenter chacune des deux dépendances pourrait être opportun. Ce posera toutefois alors la question de la possibilité de combiner les mesures de similarité établies entre ces modèles différents pour décrire la même texture.

Par ailleurs, les modèles multivariés testés dans cette étude pourraient être exploités dans un contexte de **fusion de données multi-capteurs**. La modélisation des dépendances spatiales issue d'une image optique à très haute résolution pourrait en effet se combiner à une analyse des dépendances couleur issue d'une donnée hyperspectrale et/ou à une analyse des dépendances entre canaux polarimétriques ou interférométriques d'une donnée radar.

En outre, la **pré-segmentation** réalisée par Mean-Shift et basée sur les niveaux de gris de l'image a montré quelques limites en créant localement des régions « mixtes » contenant des textures appartenant à des occupations du sol différentes. Une alternative intéressante serait de baser cette pré-segmentation sur une image multi-bandes contenant pour chaque pixel plusieurs attributs de texture issus par exemple des matrices de co-occurrence. L'algorithme de segmentation appliqué s'adapterait ainsi au contenu textural local de l'image plutôt qu'aux niveaux de gris. La méthode du Mean-Shift pourrait être à nouveau testée dans ce contexte, mais d'autres alternatives sont également possibles, telles que les SLIC (*Simple Linear Iterative Clustering*) [Achanta *et al.*, 2012] ou le BPT (*Binary Partition Tree*) proposé par [Salembier & Garrido, 2000] et déjà testé pour la classification et la segmentation d'images hyperspectrales dans [Valero *et al.*, 2010].

L'ensemble de ces perspectives illustre quelques exemples de la très large étendue des potentialités qu'il reste encore à explorer autour de l'utilisation des modèles probabilistes multivariés pour l'analyse des images de télédétection optique à très haute résolution.

# ANNEXES



# ANNEXE 1

## Stratégies d'approximation de la distance géodésique pour les modèles MGG et SIRVg0

Pour ces modèles, la mesure de similarité dépend non seulement de la matrice de covariance mais aussi des autres paramètres de la distribution. Deux stratégies d'approximation de la GD ont été proposées dans la littérature :

- Lorsque que seule la matrice de covariance  $[\mathbf{M}]$  varie entre les deux populations et que les autres paramètres du modèle (forme, échelle, etc.) sont considérés comme fixés,
- Lorsque tous les paramètres du modèle varient entre les deux populations et que les coordonnées géodésiques sont approximés par des lignes droites.

a) Distance géodésique pour des paramètres d'échelle et de forme fixes

Lorsque l'on fixe les paramètres de forme et d'échelle d'une distribution elliptique, l'expression analytique de la GD pour les modèles elliptiques SIRV et MGG est la suivante [Berkane *et al.*, 1997] :

$$GD([\mathbf{M}]_1, \alpha || [\mathbf{M}]_2, \alpha) = \left[ \left( 3b_k - \frac{1}{4} \right) \sum_{i=1}^p (r_i)^2 + 2 \left( b_k - \frac{1}{4} \right) \sum_{j=1}^p \sum_{i=1}^{j-1} r_i r_j \right]^{\frac{1}{2}} \quad (\text{A1.1})$$

où  $\alpha$  correspond aux paramètres du modèle autre que la matrice de covariance et  $r_i = \ln(\lambda_i)$  où  $\lambda_i$  désignent les valeurs propres de  $[\mathbf{M}]_1^{-1}[\mathbf{M}]_2$ . En outre,  $b_k = E\{u^2 w^2\} / (p(p+2))$  et  $w = (\partial \ln h_p) / (\partial u)$ . La densité de probabilité de  $U = \mathbf{k}'[\mathbf{M}]^{-1}\mathbf{k}$  est obtenue par [Berkane *et al.*, 1997] :

$$f_U(u) = \begin{cases} \frac{\pi^{\frac{p}{2}}}{\Gamma(\frac{p}{2})} u^{\frac{(p-1)}{2}} h_p(u) & \text{si } u > 0 \\ 0 & \text{sinon} \end{cases} \quad (\text{A1.2})$$

où  $h_p$  est la fonction générateur de densité donnée par :

$$p_k(\mathbf{k}) = \frac{1}{(\det[\mathbf{M}])^{1/2}} h_p(\mathbf{k}'[\mathbf{M}]^{-1}\mathbf{k}) \quad (\text{A1.3})$$

Cette expression analytique de la GD proposée pour les modèles elliptiques par [Berkane *et al.*, 1997] a été adapté par [Bombrun *et al.*, 2011b] et [Verdoolaege *et al.*, 2008] pour les modèles SIRVg0 et MGG respectivement. L'expression du paramètre  $b_k$  répond pour ces deux modèles aux formules suivantes :

$$b_k = \frac{1}{4} \frac{s + \frac{p}{2}}{s + \frac{p}{2} + 1} \quad (\text{SIRVg0}) \quad (\text{A1.4})$$

$$b_k = \frac{1}{4} \frac{p + 2s}{p + 2} \quad (\text{MGG}) \quad (\text{A1.5})$$

où  $s$  est le paramètre de forme des modèles. Par conséquent, pour des paramètres de forme et d'échelle fixés, une expression analytique de la GD est obtenue en remplaçant la valeur de  $b_k$  dans l'équation (A1.1). On peut constater que lorsque le paramètre de forme de la distribution SIRVg0 tend vers l'infini, ce modèle converge vers la distribution Gaussienne pour lequel  $b_k = 1/4$ . Cette remarque est également valable pour le modèle MGG où le cas dégénéré de la distribution Gaussienne est obtenue lorsque le paramètre de forme est égal à 1. Il est également intéressant de noter que dans cette procédure, la GD est indépendante du paramètre d'échelle.

#### b) Distance géodésique pour des paramètres d'échelle et de forme libres

Lorsque les paramètres de forme et d'échelle du modèle varient entre les deux populations à comparer, il est possible d'obtenir une expression de la GD en approximant les coordonnées des géodésiques par des lignes droites.

Dans le cas du modèle SIRVg0, la densité de probabilité de la distribution G0 est donnée par :

$$p_k(\mathbf{k}|m, s, [\mathbf{M}]) = \frac{1}{(2\pi)^{p/2} \det[\mathbf{M}]^{1/2}} \frac{(sm)^s}{\Gamma(s)} \Gamma\left(\frac{p}{2} + s\right) \left(\frac{\mathbf{k}'[\mathbf{M}]^{-1}\mathbf{k}}{2} + sm\right)^{-(s+\frac{p}{2})} \quad (\text{A1.6})$$

La distance géodésique entre deux distributions multivariées G0 de paramètres  $(m_1, s_1, [\mathbf{M}]_1)$  et  $(m_2, s_2, [\mathbf{M}]_2)$  est la mesure du plus court chemin le long d'une variété Riemannienne. Selon l'équation (2.4) :

$$GD(m_1, s_1, [\mathbf{M}]_1 || m_2, s_2, [\mathbf{M}]_2) = \int_0^1 \sqrt{\sum_{\mu, \nu} g_{\mu\nu} \dot{\theta}^\mu \dot{\theta}^\nu} dt \quad (\text{A1.7})$$

où  $\theta = (m, s, r^1, \dots, r^p)$  est un vecteur contenant les paramètres de la distribution G0 et  $\theta^\mu$  est le  $\mu$ -ème paramètre du vecteur  $\theta$ ,  $g_{\mu\nu}$  est l'élément en position  $(\mu, \nu)$  de la matrice d'information de Fisher de taille  $(p + 2) \times (p + 2)$  définie par :

$$\mathbf{G} = \begin{bmatrix} g_{mm} & g_{ms} & g_{mi} & \cdots & \cdots & g_{mi} \\ g_{ms} & g_{ss} & g_{si} & \cdots & \cdots & g_{si} \\ g_{mi} & g_{si} & g_{ii} & g_{ij} & \cdots & g_{ij} \\ \vdots & \vdots & g_{ij} & \ddots & \ddots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \ddots & \vdots \\ g_{mi} & g_{si} & g_{ij} & \cdots & g_{ij} & g_{ii} \end{bmatrix} \quad (\text{A1.8})$$

Il a été démontré dans [Bombrun *et al.*, 2011b] que tous les éléments de cette matrice d'information de Fisher peuvent s'exprimer en fonction des deux paramètres de forme et d'échelle. L'expression de la GD est finalement obtenue en utilisant l'équation (A1.7) et en approximant les coordonnées géodésiques par des lignes droites, c'est-à-dire que l'on considère qu'à  $t = 0$  (respectivement  $t = 1$ ), on se trouve sur la variété au point correspondant à la première (respectivement la deuxième) distribution :

$$\begin{cases} m(t) = m_1(1 - t) + m_2 t \\ s(t) = s_1(1 - t) + s_2 t \\ r^i(t) = r_i t \end{cases} \quad (\text{A1.9})$$

Cette stratégie constitue uniquement une approximation de la GD, la géodésique existant par définition sur une variété courbe. Une même méthodologie d'estimation de la GD a été également proposée pour la MGG dans [Verdoolaege & Scheunders, 2012].



## ANNEXE 2

### Cartographie des pratiques culturales d'enherbement en Entre-Deux-Mers

Contrairement aux appellations ciblées lors de l'étude présentée au chapitre IV (pour rappel : Pessac-Léognan, Saint-Emilion et Sauternes), l'appellation viticole de l'Entre-Deux-Mers est caractérisée par une densité de plantation de vignes plus faible et par conséquent, par une distance inter-rang plus large de l'ordre de 2 à 3 m. Cela se traduit par une capacité de distinction plus grande des rangs de plantation et *a fortiori* des espaces inter-rang dans les images à très haute résolution de type Pléiades. De plus, cette appellation se différencie des autres appellations précédemment étudiées par une plus grande diversité de pratiques culturales, en particulier en termes d'enherbement. Cette pratique consiste à semer un mélange d'espèces de graminées à l'inter-rang afin de provoquer une compétition en surface pour les nutriments et ainsi forcer la vigne à puiser ses ressources plus en profondeur dans le sol. Plusieurs stratégies d'application de cette pratique sont recensées. Les plus fréquentes en Entre-Deux-Mers consistent en un enherbement complet (tous les inter-rangs sont enherbés), ou un enherbement partiel appliqué généralement un rang sur deux (Figure A2.1).




Figure A2.1 : Exemples de pratiques d'enherbement, enherbement complet (gauche), enherbement partiel un rang sur deux (droite). Les images en dessous illustrent les deux pratiques par des extraits de l'image Pléiades du 15/04/2014.

Grâce à la très haute résolution des images Pléiades et les espaces inter-rang plus larges observés dans cette appellation, une cartographie de cette pratique culturale est donc potentiellement faisable. L'objectif de cette étude complémentaire est donc de tester les modèles multivariés dans ce contexte de caractérisation intra-parcellaire de la pratique d'enherbement. Pour ce faire, deux types de données ont été exploités. Le premier est une image panchromatique Pléiades acquises sur une partie de l'appellation le 15/04/2014. Le deuxième est une base de données d'observations de terrain acquise le 07/07/2014 et portant sur 198 parcelles localisées dans l'image Pléiades. Pour chaque parcelle échantillonnée pendant cette campagne, la pratique d'enherbement a été relevée. Deux classes sont ainsi considérées : enherbement complet (55 parcelles) et enherbement partiel un rang sur deux (143 parcelles). Par ailleurs, les contours des parcelles observées sont dessinés à la main et conservés dans une base de données géographique vectorielle<sup>5</sup>.

La stratégie de classification employée est identique à celle utilisée dans le cas de la classification des classes d'âge de forêt au chapitre III et présentée à la Figure 2.3 A. Les attributs de texture sont extraits de toutes les parcelles observées en faisant appel à cinq approches d'analyse texturale : les matrices de co-occurrence (GLCM), le modèle multivarié Gaussien avec estimateur SCM (SCM), les modèles SIRV Gaussien (SIRVgauss) et G0 (SIRVg0) et le modèle Gamma sur Copule Gaussienne (GCG). Une fois les attributs extraits pour tous les modèles, une procédure de validation croisée est réalisée en séparant aléatoirement la base de données à chaque itération en base d'apprentissage et de validation. Deux classifieurs sont mis en œuvre :  $k$ -NN et SVM. Comme précédemment, l'effet de l'orientation des textures est évalué en créant une seconde base de données dans laquelle chaque parcelle analysée est préalablement retournée afin de forcer son orientation dominante à 0° (SProt). Les résultats de validation croisée avec les classifieurs  $k$ -NN et SVM sont présentés à la Figure A2.2.

De manière générale, les résultats obtenus ne montrent pas de différences significatives entre les modèles multivariés testés et les GLCMs. On peut toutefois remarquer des précisions globales de classification moyennes plus élevées pour les GLCMs que pour les modèles multivariés et ce quel que soit le modèle, la modalité testée (SP ou SProt) et le classifieur ( $k$ -NN ou SVM). Parmi les modèles multivariés, les modèles GCG et SIRVg0 affichent des performances plus élevées que les modèles SCM et SIRVgauss dans la modalité SP avec le classifieur  $k$ -NN. Le fait d'uniformiser l'orientation dominante dans la base de données (SProt) permet d'améliorer les performances des modèles multivariés. Cela confirme le manque d'invariance à la rotation des approches par décomposition en ondelettes déjà observé dans les autres études thématiques. A nouveau, l'utilisation du classifieur SVM permet d'améliorer les performances pour toutes les approches et réduit l'écart entre les modalités SP et SProt.

Compte tenu du contexte de classification à deux classes, les précisions de classification obtenues pour l'ensemble des approches sont globalement faibles et dépassent rarement les 80 %. Comme dans l'étude relative à la différenciation de classes d'âge de forêt, nous sommes confrontés ici à la différence entre l'hypothèse de départ (les parcelles à enherbement partiel et enherbement complet exhibent une texture différente) et la réalité de terrain. En effet, dans un nombre de cas significatif (approximativement 20 %), la texture exhibée par les parcelles analysées ne correspond pas à la classe à laquelle cette parcelle appartient. La classe des parcelles partiellement enherbées est généralement associée à un taux élevé de bonne classification pour tous les modèles (Tableau A2.1). Les erreurs de classification concernent donc essentiellement les parcelles complètement enherbées. Plusieurs

<sup>5</sup> Une approche telle que celle proposée dans [Rabatel *et al.*, 2008] aurait pu être utilisée ici pour récupérer ces contours de manière automatique.




Figure A2.2 : Précision globale moyenne (Overall Accuracy) par validation croisée avec un classifieur  $k$ -NN ( $k = 10$ ) (gauche) et un classifieur SVM (droite). SP = dépendance spatiale, SPProt = dépendance spatiale avec rotation. Les barres d'erreur indiquent l'écart-type sur 100 itérations.

Tableau A2.1 : Précision de classification obtenue pour la modalité SP avec un classifieur  $k$ -NN.

	Enherbement partiel		Enherbement complet		OA
	PA	UA	PA	UA	
GLCM	92.47	<b>80.15</b>	<b>40.82</b>	<b>69.1</b>	<b>78.01</b>
SCM	91.33	77.28	30.71	59.97	74.36
SIRVgauss	89.53	76.26	28.14	53.97	72.34
SIRVg0	91.83	78.58	35.32	64.34	76.01
GCG	<b>93.00</b>	78.59	34.50	68.06	76.62

PA = Précision du producteur – UA = Précision de l'utilisateur – OA = Précision globale

sources d'erreurs peuvent être identifiées. La densité de l'enherbement même lorsqu'il est complet, peut être localement hétérogène en raison de différences locales de fertilité ou de passage d'engins agricoles (voir zones plus claires dans Figure A2.1 gauche). Les parcelles complètement enherbées partagent alors des aspects communs avec celles qui le sont partiellement. Par ailleurs, un nombre significatif de parcelles dans lesquelles est pratiqué l'enherbement complet sont marquées par une densité de plantation plus élevée (distance inter-rang inférieure à 2 m). L'écartement plus serré entre les rangs ne permet alors plus de distinguer nettement les pratiques d'enherbement et des confusions peuvent se produire. En outre, entre l'acquisition de l'image et les observations sur le terrain, plusieurs mois se sont écoulés. Des opérations de nettoyage des rangs ont pu se dérouler entre-temps et provoquer des différences entre les deux jeux de données.

Contrairement aux performances obtenues lors de la classification des âges de peuplements forestiers ou lors de la détection de parcelles viticoles, les résultats atteints avec les GLCMs sont ici équivalents à ceux obtenus avec les modèles multivariés. Les textures analysées dans ce contexte sont en effet plus simples que dans le cas de la forêt où une hétérogénéité plus forte des textures est présente. A l'inverse des autres appellations viticoles bordelaises, les parcelles viticoles en Entre-Deux-Mers montrent également moins d'hétérogénéités intra-parcellaires. Etant donné cette homogénéité des textures, les GLCMs produisent d'aussi bons résultats que les modèles multivariés. De plus, dans cette étude, les deux classes de texture comparées sont anisotropes. Cela donne également un avantage aux GLCMs grâce aux descripteurs invariants à la rotation qu'elles produisent.

En conclusion, la caractérisation intra-parcellaire des pratiques d'enherbement, rendue possible en Entre-Deux-Mers par une distance inter-rang plus large, est tout aussi efficacement réalisée avec les GLCMs qu'avec certains des modèles multivariés testés. Une approche d'analyse texturale telle que celle fondée sur les matrices de co-occurrence est donc à privilégier dans ce contexte compte tenu de sa simplicité de mise en œuvre. Cette conclusion rejoint celle formulée dans le chapitre IV selon lesquelles les modèles multivariés sont généralement plus efficaces que les autres méthodes lorsque la texture est partiellement atténuée dans les parcelles viticoles. En Entre-Deux-Mers, ce n'est pas le cas. On gardera également à l'esprit les divergences qu'il peut y avoir entre la réalité du terrain et les différences théoriques entre les classes à distinguer. Ces divergences propres au contexte applicatif entraînent invariablement des erreurs de classification quelle que soit la méthode d'analyse texturale utilisée.



# Bibliographie

- ACHANTA R., SHAJI A., SMITH K., LUCCHI A., FUA P., SUSSTRUNK S., 2012. SLIC superpixels compared to state-of-the-art superpixels methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 34, no. 11, pp. 2274-2281.
- AKSOY S., AKÇAY G., WASSENAAR T., 2010. Automatic mapping of linear woody vegetation features in agricultural landscapes. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 48, no. 1, pp. 511-522.
- AKSOY S., YALNIZ I. Z., TASDEMİR K., 2012. Automatic detection and segmentation of orchards using very high resolution imagery. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 50, no. 8, pp. 3117-3131.
- ALLILI M. S., 2012. Wavelet modeling using finite mixtures of generalized Gaussian distributions: application to texture discrimination and retrieval. *IEEE Transactions on Image Processing*, vol. 21, no. 4, pp. 1452-1464.
- ARGENTI F., BIANCHI T., ALPARONE L., 2006. Multiresolution MAP despeckling of SAR images based on locally adaptative generalized Gaussian pdf modeling. *IEEE Transactions on Image Processing*, vol. 15, no. 1, pp. 3385-3399.
- ARIVAZHAGAN S., GANESAN L., 2003. Texture segmentation using wavelet transform. *Pattern Recognition Letters*, vol. 24, pp. 3197-3203.
- ARIVAZHAGAN S., GANESAN L., KUMAR T. S., 2006. Texture classification using curvelet statistical and co-occurrence features. *Proceedings of the 2006 IEEE International Conference on Pattern Recognition*, pp. 938-941.
- AUGUSTEIJN M. F., CLEMENS L. E., SHAW K. A., 1995. Performance evaluation of texture measure for ground cover identification in satellite images by means of a neural network classifier. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 33, no. 3, pp. 616-626.
- BALAGUER A., RUIZ L. A., HERMOSILLA T., RECIO J. R., 2010. Definition of a comprehensive set of texture semivariogram features and their evaluation for object-oriented image classification. *Computers and Geosciences*, vol. 36, pp. 231-240.
- BAZI Y., BRUZZONE L., MELGANI F., 2005. An unsupervised approach based on the generalized Gaussian model to automatic change detection in multitemporal SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, no. 4, pp. 874-887.
- BEGUET B., BOUKIR S., GUYON D., CHEHATA N., 2013. Modelling-based feature selection for classification of forest structure using very high resolution multispectral imagery. *IEEE 2013 International Conference on Systems, Man, and Cybernetics*, pp. 4294-4299.
- BEGUET B., GUYON D., BOUKIR S., CHEHATA N., 2014. Automated retrieval of forest structure variables based on multi-scale texture analysis of VHR satellite imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 96, pp. 164-178.
- BENTLER P. M., BONETT D. G., 1980. Significance tests and goodness of fit in the analysis of covariance structures. *Psychological Bulletin*, vol. 88, no. 3, pp. 588-606.
- BERKANE M., ODEN K., BENTLER P. M., 1997. Geodesic estimation in elliptical distributions. *Journal of Multivariate Analysis*, vol. 63, pp. 35-46.
- BIGUN J., GRANLUND G. H., WIKLUND J., 1991. Multidimensional orientation estimation with applications to texture analysis and optical flow. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 13, no. 8, pp. 775-790.

- BLASCHKE T., 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 65, pp. 2-16.
- BOMBRUN L., ANFINSEN S. N., HARANT O., 2011a. A complete coverage of log-cumulant space in terms of distributions for polarimetric SAR data. In *5th International Workshop on Science and Applications of SAR Polarimetry and Polarimetric Interferometry (POLinSAR 2011)*.
- BOMBRUN L., BERTHOUMIEU Y., LASMAR N.-E., VERDOOLAEGE G., 2011b. Multivariate texture retrieval using the geodesic distance between elliptically distributed random variables. *Proceedings of the 2011 IEEE International Conference on Image Processing*, pp. 3637-3640.
- BOMBRUN L., VASILE G., GAY M., TOTIR F., 2011c. Hierarchical segmentation of polarimetric SAR images using heterogeneous clutter models. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 49, no. 2, pp. 726-737.
- BOSER B. E., GUYON I., VAPNIK V. N., 1992. A training algorithm for optimal margin classifiers. *Proceedings of the fifth annual workshop on Computational learning theory*, pp. 144-152.
- BRODATZ. Brodatz Texture Images.  
<http://www.ux.uis.no/tranden/brodatz.html>
- CAMPBELL F. W., ROBSON J. G., 1968. Application of Fourier analysis to the visibility of gratings. *Journal of Physiology*, vol. 197, pp. 551-566.
- CHAMPION I., GERMAIN C., DA COSTA J.-P., ALBORINI A., DUBOIS-FERNANDEZ P., 2014. Retrieval of forest stand age from SAR image texture for varying distance and orientation values of the Gray Level Co-occurrence Matrix. *IEEE Geoscience and Remote Sensing Letters*, vol. 11, no.1, pp. 5-9.
- CHANG T., KUO C.-C. J., 1993. Texture analysis and classification with tree-structured wavelet transform. *IEEE Transactions on Image Processing*, vol. 2, no. 4, pp. 429-441.
- CHANG C. C., LIN C. J., 2011. LIBSVM: a library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, vol. 2, no. 3, pp. 27.  
<http://www.csie.ntu.edu.tw/~cjlin/libsvm>
- CHANUSSOT J., BAS P., BOMBRUN L., 2005. Airborne remote sensing of vineyards for the detection of dead vine trees. *Proceedings of the 2005 IEEE International Geoscience and Remote Sensing Symposium*, pp. 3090-3093.
- CHARALAMPIDIS D., KASPARIS T., 2002. Wavelet-based rotational invariant roughness features for texture classification and segmentation. *IEEE Transactions on Image Processing*, vol. 11, no. 8, pp. 825-837.
- CHEHATA N., LE BRIS A., LAGACHERIE P., 2013. Comparison of VHR panchromatic texture features for tillage mapping. *Proceedings of the 2013 IEEE International Geoscience and Remote Sensing Symposium*, pp. 3128-3131.
- CHOE B.-H., KIM D.-J., HWANG J.-H., OH Y., MOON W. M., 2012. Detection of oyster habitat in tidal flats using multi-frequency polarimetric SAR data. *Estuarine, Coastal and Shelf Science*, vol. 97, pp. 28-37.
- CHOY S. K., TONG C. S., 2010. Statistical wavelet subband characterization based on generalized Gamma density and its application in texture retrieval. *IEEE Transactions on Image Processing*, vol. 19, no. 2, pp. 281-289.
- CLAUSI D. A., 2002. An analysis of co-occurrence texture statistics as a function of grey level quantization. *Canadian Journal of Remote Sensing*, vol. 28, no. 1, pp. 45-62.
- CLAUSI D. A., DENG H., 2005. Design-based texture feature fusion using Gabor filters and co-occurrence probabilities. *IEEE Transactions on Image Processing*, vol. 14, no. 7, pp. 925-936.
- COBURN C. A., ROBERTS A. C. B., 2004. A multiscale texture analysis procedure for improved forest stand classification. *International Journal of Remote Sensing*, vol. 25, no. 20, pp. 4287-4308.



- COHEN J., 1960. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, vol. 20, pp. 37-46.
- COMANICIU D., MEER P., 2002. Mean shift: a robust approach toward feature space analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, no. 5, pp. 603-619.
- CONGALTON R. G., 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, vol. 37, no. 1, pp. 35-46.
- CONNERS R. W., TRIVEDI M. M., HARLOW C. A., 1984. Segmentation of high-resolution urban scene using texture operators. *Computer Vision, Graphics, and Image Processing*, vol. 25, pp. 273-310.
- CROSS G. R., JAIN A. K., 1983. Markov random field texture models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. PAMI-5, no. 1, pp. 25-39.
- CRPFA, 2008. Le pin maritime – Pilier de l'économie forestière d'Aquitaine. *Fiches techniques du Centre Régional de la Propriété Forestière d'Aquitaine*.
- CURRAN P. J., 1988. The semivariogram in remote sensing: an introduction. *Remote Sensing of Environment*, vol. 24, pp. 493-507.
- DAUBECHIES I., 1992. Ten lectures on wavelet. *Society for Industrial and Applied Mathematics*.
- DAVIS L. S., JOHNS S. A., AGGARWAL J. K., 1979. Texture analysis using generalized co-occurrence matrices. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. PAMI-1, no. 3, pp. 251-259.
- DAVIS J., GOADRICH M., 2006. The relationship between Precision-Recall and ROC curves. *Proceedings of the 2006 International Conference on Machine Learning*, pp. 233-240.
- DE MARTINO M., CAUSA F., SERPICO S. B., 2003. Classification of optical high resolution images in urban environment using spectral and textural information. *Proceedings of the 2003 IEEE International Geoscience and Remote Sensing Symposium*, pp. 467-469.
- DE VALOIS R. L., ALBRECHT D. G., THORELL L. G., 1982. Spatial-frequency selectivity of cells in macaque visual cortex. *Vision Research*, vol. 22, pp. 545-559.
- DO M. N., VETTERLI M., 2002. Wavelet-based texture retrieval using generalized Gaussian density and Kullback-Leibler distance. *IEEE Transactions on Image Processing*, vol. 11, no. 2, pp. 146-158.
- DO M. N., VETTERLI M., 2003. The finite ridgelet transform for image representation. *IEEE Transactions on Image Processing*, vol. 12, no. 1, pp. 16-28.
- FRANKLIN S. E., HALLS R. J., MOSKAL L. M., MAUDIE A. J., LAVIGNE M. B., 2000. Incorporating texture into classification of forest species composition from airborne multispectral images. *International Journal of Remote Sensing*, vol. 21, no. 1, pp. 61-79.
- FRANKLIN S. E., WULDER M. A., GERYLO G. R., 2001. Texture analysis of IKONOS panchromatic data for Douglas-fir forest age class separability in British Columbia. *International Journal of Remote Sensing*, vol. 22, no. 13, pp. 2627-2632.
- FREITAS C. C., FRERY A. C., CORREIA A. H., 2005. The polarimetric G distribution for SAR data analysis. *Environmetrics*, vol. 16, pp. 13-31.
- FUKUDA S., HIROSAWA H., 1999. A wavelet-based texture feature set applied to classification of multifrequency polarimetric SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 37, no. 5, pp. 2282-2286.
- GADE M., MELCHIONNA S., STELZER K., KOHLUS J., 2014. Multi-frequency SAR data help improving the monitoring of intertidal flats on the German North Sea Coast. *Estuarine, Coastal and Shelf Science*, vol. 140, pp. 32-42.
- GERMAIN C., ALAIN M., DA COSTA J.-P., LAFON V., 2012. Oyster bed mapping and evaluation of the Maritime Public Domain status. *Pléiades Days 2012*.

- GINI F., GRECO M., 2002. Covariance matrix estimation for CFAR detection in correlated heavy tailed clutter. *Signal Processing*, vol. 82, pp. 1847-1859.
- GLEICH D., DATCU M., 2009. Wavelet-based SAR image despeckling and information extraction, using particle filter. *IEEE Transactions on Image Processing*, vol. 18, no. 10, pp. 2167-2184.
- GOODMAN N. R., 1963. Statistical analysis based on a certain multivariate complex Gaussian distribution (an introduction). *Annals of Mathematical Statistics*, pp. 152-177.
- HARALICK R. M., 1979. Statistical and structural approaches to texture. *Proceedings of the IEEE*, vol. 67, no. 5, pp. 786-804.
- HARALICK R. M., SHANMUGAM K., DINSTEN I., 1973. Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, SMC-3, no. 6, pp. 610-621.
- HARANT O., BOMBRUN L., GAY M., FALLOURD R., TROUVE E., TUPIN F., 2009. Segmentation and classification of polarimetric SAR data based on the KummerU distribution. In *2009 International Workshop on Science and Applications of SAR Polarimetry and Polarimetric Interferometry (POLinSAR 2009)*.
- HU R., FAHMY M. M., 1992. Texture segmentation based on a hierarchical Markov random field model. *Signal Processing*, vol. 26, pp. 285-305.
- IFN, 2009. Tempête Klaus du 24 janvier 2009 : 234 000 hectares de forêts affectés à plus de 40% - 42,5 millions de mètres cube de dégât. *IF*, no. 21, 12p.
- JAYASUMANA S., HARTLEY R., SALZMANN M., LI H., HARANDI M., 2013. Kernel methods on Riemannian manifold symmetric positive definite matrices. *Proceedings of the 2013 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 73-80.
- JAMES A. T., 1973. The variance information manifold and the functions on it. *Multivariate Analysis*, vol. 3, pp. 157-169.
- JOE H., XU J. J., 1996. The estimation method of inference functions for margins for multivariate models. Technical report no. 166, Department of Statistics, University of British Columbia.
- JOHANSEN K., COOPS N. C., GERGEL S. E., STANGE Y., 2007. Application of high spatial resolution satellite imagery for riparian and forest ecosystem classification. *Remote Sensing of Environment*, vol. 110, pp. 29-44.
- JULESZ B., 1962. Visual pattern discrimination. *IRE Transactions on Information Theory*, vol. IT-8, pp. 84-92.
- JULESZ B., 1981. Textons, the elements of texture perception, and their interactions. *Nature*, vol. 290, no. 5802, pp. 91-97.
- JULESZ B., GILBERT E. N., VICTOR J. D., 1978. Visual discrimination of textures with identical third-order statistics. *Biological Cybernetics*, vol. 31, no. 3, pp. 137-140.
- KABIR S., HE D.-C., SANUSI M. A., WAN HUSSIN W. M. A., 2010. Texture analysis of IKONOS satellite imagery for urban land and land cover classification. *The Imaging Science Journal*, vol. 58, no. 3, pp. 163-170.
- KAYITAKIRE F., HAMEL C., DEFOURNY P., 2006. Retrieving forest structure variables based on image texture analysis and IKONOS-2 imagery. *Remote Sensing of Environment*, vol. 102, pp. 390-401.
- KEERTHI S. S., LIN C. J., 2003. Asymptotic behavior of support vector machines with Gaussian kernel. *Neural Computation*, vol. 15, no. 7, pp. 1667-1689.
- KHAN S., DOULGERIS A P., SAVASTANO S., GUIDA R., 2014. Automatic clustering of multispectral data using a non-Gaussian statistical model. *Proceedings of the 2014 IEEE International Geoscience and Remote Sensing Symposium*, pp. 4276-4279.

- KIM M., MADDEN M., WARNER T. A., 2009. Forest type mapping using object-specific texture measures from multispectral IKONOS imagery: segmentation quality and image classification issues. *Photogrammetric Engineering and Remote Sensing*, Vol. 75, no. 7, pp. 819-829.
- KWITT R., UHL A., 2008. Image similarity measurement by Kullback-Leibler divergences between complex wavelet subband statistics for texture retrieval. *Proceedings of the 2008 IEEE International Conference on Image Processing*, pp. 933-936.
- KWITT R., UHL A., 2009. A joint model of complex wavelet coefficients for texture retrieval. *Proceedings of the 2009 IEEE International Conference on Image Processing*, pp. 1877-1880.
- LAINE A., FAN J., 1993. Texture classification by wavelet packet signatures. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 15, no. 11, pp. 1186-1191.
- LAFON V., MUGICA J., MALLET C., DEHOUC A., 2014. Cartographie de l'état de parcs ostréicoles par télédétection très haute résolution. Application au domaine concédé du Bassin d'Arcachon. *Revue Paralia*, vol. 7, pp. s03.1-s03.12.
- LASMAR N.-E., STITOU Y., BERTHOUMIEU Y., 2009. Multiscale skewed heavy tailed model for texture analysis. *Proceedings of the 2009 IEEE International Conference on Image Processing*, pp. 2281-2284.
- LASMAR N.-E., BERTHOUMIEU Y., 2010. Multivariate statistical modeling for texture analysis using wavelet transforms. *Proceedings of the 2010 IEEE International Conference on Acoustics, Speech and Signal Processing*, pp. 790-793.
- LASMAR N.-E., BERTHOUMIEU Y., 2014. Gaussian copula multivariate modeling for texture image retrieval using wavelet transforms. *IEEE Transactions on Image Processing*, vol. 23, no. 5, pp. 2246-2261.
- LAVIALLE O., TEREDES R., GERMAIN C., DA COSTA J.-P., GRENIER G., 2003. Diffusion orientée pour le filtrage d'images : application à l'amélioration d'images aériennes de parcelles de vignes. *Colloque sur le traitement d'images et du signal – GRETSI 2003*.
- LE BRIS A., 2012. Extraction of vineyards out of aerial ortho-image using texture information. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 1, pp. 383-388.
- LEFEBVRE A., CORPETTI T., HUBERT MOY L., 2011. Estimation of the orientation of textured patterns via wavelet analysis. *Pattern Recognition Letters*, vol. 32, pp. 190-196.
- LENGLET C., ROUSSON M., DERICHE R., FOUGERAS O., 2006. Statistics on the manifold of multivariate normal distributions: Theory and application to diffusion tensor MRI processing. *Journal of Mathematical Imaging and Vision*, vol. 25, no. 3, pp. 423-444.
- LE POULIQUEN F., DA COSTA J.-P., GERMAIN C., BAYLOU P., 2005. A new adaptative framework for unbiased orientation estimation in textured images. *Pattern Recognition*, vol. 38, no. 11, pp. 2032-2046.
- LÉVESQUE J., KING D. J., 2003. Spatial analysis of radiometric fractions from high-resolution multispectral imagery for modeling individual tree crown and forest canopy structure and health. *Remote Sensing of Environment*, vol. 84, pp. 589-602.
- LI N., HUO H., FANG T., 2010. A novel texture-precede segmentation algorithm for high-resolution imagery. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 48, no. 7, pp. 2818-2828.
- LO E. H. S., PICKERING M. R., FRATER M. R., ARNOLD J. F., 2007. Image segmentation using invariant texture features from the double dyadic dual-tree complex wavelet transform. *Image and Vision Computing*, vol. 29, no. 1, pp. 15-28.
- LUCIEER A., VAN DER WERFF H., 2007. Panchromatic wavelet texture features fused with multispectral bands for improved classification of high-resolution satellite imagery. *Proceedings of the 2007 IEEE International Geoscience and Remote Sensing Symposium*, pp. 5154-5157.

- MA W. Y., MANJUNATH B. S., 1998. A texture thesaurus for browsing large aerial photographs. *Journal of the American Society for Information Sciences*, vol. 49, no. 7, pp. 633-648.
- MAILLARD P., 2003. Comparing texture analysis methods through classification. *Photogrammetric Engineering and Remote Sensing*, vol. 69, no. 4, pp. 357-368.
- MALLAT S., 1989. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, no. 7, pp. 674-693.
- MANJUNATH B. S., MA W. Y., 1996. Texture features for browsing and retrieval of image data. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 18, no. 8, pp. 837-842.
- MANTERO P., MOSER G., SERPICO S. B., 2005. Partially supervised classification of remote sensing images through SVM-based probability density estimation. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, no. 3, pp. 559-570.
- MATHIASSEN J. R., SKAVHAUG A., BO K., 2002. Texture similarity measure using Kullback-Leibler divergence between Gamma distributions. *Computer Vision-ECCV 2002*, pp. 133-147.
- MERCIER G., MOSER G., SERPICO S. B., 2008. Conditional copulas for change detection in heterogeneous remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 46, no. 5, pp. 1428-1441.
- MERZEAU D., 1995. Une culture traditionnelle, un moteur économique. *Forêt-Entreprises*, no. 105, pp. 33-44.
- MICHELET F., DA COSTA J.-P., LAVIALLE O., BERTHOUMIEU Y., BAYLOU P., GERMAIN C., 2007. Estimating local multiple orientations. *Signal Processing*, vol. 87, no. 7, pp. 1655-1669.
- MITCHELL A. F. S., 1988. Statistical manifolds of univariate elliptical distributions. *International Statistical Review*, vol. 56, pp. 464-467.
- MOUNTRAKIS G., IM J., OGOLE C., 2011. Support vector machines in remote sensing: a review. *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 66, no. 3, pp. 247-259.
- MÜLLER H., MÜLLER W., SQUIRE D. M., MARCHAND-MAILLET S., PUN T., 2001. Performance evaluation in content-based image retrieval: overview and proposals. *Pattern Recognition Letters*, vol. 22, pp. 593-601.
- NEWSAM S. D., KAMATH C., 2004. Retrieval using texture features in high-resolution multispectral satellite imagery. *Defense and Security, International Society for Optics and Photonics*, pp. 21-32.
- OJALA T., PIETIKAINEN M., HARWOOD D., 1996. A comparative study of texture measures with classification based on feature distributions. *Pattern Recognition*, vol. 29, no. 1, pp. 51-59.
- OUMA Y. O., TATEISHI R., SRI-SUMANTYO J. T., 2010. Urban features recognition and extraction from very-high resolution multi-spectral satellite imagery: a micro-macro texture determination and integration framework. *Image Processing, IET*, vol. 4, no. 4, pp. 235-254.
- OZDEMIR I., KARNIELI A., 2011. Predicting forest structural parameters using image texture derived from WorldView-2 multispectral imagery in a dryland forest, Israel. *International Journal of Applied Earth Observation and Geoinformation*, vol. 13, pp. 701-710.
- PACIFICI F., CHINI M., EMERY W. J., 2009. A neural network approach using multi-scale textural metrics from very high-resolution panchromatic imagery for urban land-use classification. *Remote Sensing of Environment*, vol. 113, no. 6, pp. 1276-1292.
- PAL M., MATHER P. M., 2005. Support vector machines for classification in remote sensing. *International Journal of Remote Sensing*, vol. 26, no. 5, pp. 1007-1011.
- PASCAL F., CHITOUR Y., OVARLEZ J.-P., FORSTER P., LAZARBAL P., 2008. Covariance structure maximum-likelihood estimates in compound Gaussian noise: existence and algorithm analysis. *IEEE Transactions on Signal Processing*, vol. 56, no. 1, pp. 34-48.

- PASHER J., KING D. J., 2010. Multivariate forest structure modeling and mapping using high resolution airborne imagery and topographic information. *Remote Sensing of Environment*, vol.114 pp. 1718-1732.
- PERONA P., MALIK J., 1990. Scale-space and edge detection using anisotropic diffusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 12, no. 7, pp. 629-639.
- PESARESI M., BENEDIKTSSON J. A., 2001. A new approach for the morphological segmentation of high-resolution satellite imagery. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 39, no. 2, pp. 309-320.
- PESARESI M., GEHARDINGER A., KAYITAKIRE F., 2008. A robust built-up area presence index by anisotropic rotation-invariant textural measure. *IEEE International Journal on Selected Topics in Applied Earth Observations and Remote Sensing*, Vol. 2, no. 3, pp. 180-192.
- PO D. Y., DO M. N., 2006. Directional multiscale modeling of images using the contourlet transform. *IEEE Transactions on Image Processing*, vol. 15, no. 6, pp. 1610-1620.
- PORTILLA J., SIMONCELLI E. P., 2000. A parametric texture model based on joint statistics of complex wavelet coefficients. *International Journal of Computer Vision*, vol. 40, no. 1, pp. 49-71.
- PROISY C., COUTERON P., FROMARD F., 2007. Predicting and mapping biomass from canopy grain analysis using Fourier-based textural ordination of IKONOS images. *Remote Sensing of Environment*, vol.109, pp. 379-392.
- PUISSANT A., HIRSCH J., WEBER C., 2005. The utility of texture analysis to improve per-pixel classification for high to very high spatial resolution imagery. *International Journal of Remote Sensing*, vol. 26, no. 4, pp. 733-745.
- RABATEL G., DELENNE C., DESHAYES M., 2008. A non supervised approach using Gabor filters for vine-plot detection in aerial images. *Computers and Electronics in Agriculture*, vol. 62, pp. 159-168.
- RANCHIN T., NAERT B., ALBUISSON M., BOYER G., ASTRAND P., 2001. An automatic method for vine detection in airborne imagery using wavelet transform and multiresolution analysis. *Photogrammetric Engineering and Remote Sensing*, vol. 67, no. 1, pp. 91-98.
- RANDEN T., HUSOY J. H., 1999. Filtering for texture classification: a comparative study. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 21, no. 4, pp. 291-310.
- RAO C. R., 1945. Information and accuracy attainable in the estimation of statistical parameters. *Bulletin of the Calcutta Mathematical Society*, vol. 37, no. 3, pp. 81-91.
- REGNIERS O., DA COSTA J.-P., GRENIER G., GERMAIN C., BOMBRUN L., 2013. Texture based image retrieval and classification of very high resolution maritime pine forest images. *Proceedings of the 2013 IEEE International Geoscience and Remote Sensing Symposium*, pp. 4038-4041.
- REGNIERS O., BOMBRUN L., GERMAIN C., 2014a. Modélisation de texture basée sur les ondelettes pour la détection de parcelles viticoles à partir d'images Pléiades panchromatiques. *Revue Française de Photogrammétrie et de Télédétection*, vol. 208, pp. 117-122.
- REGNIERS O., BOMBRUN L., GUYON D., SAMALENS J.-C., GERMAIN C., 2014b. Wavelet-based texture features for the classification of age classes in a maritime pine forest. *IEEE Geoscience and Remote Sensing Letters*, vol. 12, no. 3, pp. 621-625.
- REGNIERS O., BOMBRUN L., GUYON D., SAMALENS J.-C., TINEL C., GRENIER G., GERMAIN C., 2014c. Wavelet based texture modeling for the classification of very high resolution maritime pine forest images. *Proceedings of the 2014 IEEE International Geoscience and Remote Sensing Symposium*, pp. 2027-203.

- REGNIERS O., BOMBRUN L., LAFON V., DEHOUC A., TINEL C., GERMAIN C., 2014d. Wavelet based texture modeling for panchromatic very high resolution image classification: application to oyster racks detection. *Proceedings of the 2014 IEEE International Geoscience and Remote Sensing Symposium*, pp. 5148-5151.
- RUIZ L. A., FERNANDEZ-SARRIA A., RECIO J. A., 2004. Texture feature extraction for classification of remote sensing data using wavelet decomposition: a comparative study. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XXXV-B4, pp. 1109-1114.
- RUIZ L. A., RECIO J. A., FERNANDEZ-SARRIA A., HERMOSILLA T., 2011. A feature extraction software tool for agricultural object-based image analysis. *Computers and Electronics in Agriculture*, vol. 76, pp. 284-296.
- RYU J.-H., CHOI J.-K., LEE Y.-K., 2014. Potential of remote sensing in management of tidal flats: A case study of thematic mapping in the Korean tidal flats. *Ocean & Coastal Management*, 2014, pp. 1-13.
- SALEMBIER P., GARRIDO L., 2000. Binary partition tree as an efficient representation for image processing, segmentation, and information retrieval. *IEEE Transactions on Image Processing*, vol. 9, no. 4, pp. 561-576.
- SALICRU M., MORALES D., MENENDEZ M. L., PARDO L., 1994. On the applications of divergence type measures in testing statistical hypotheses. *Journal of Multivariate Analysis*, vol. 51, pp. 372-391.
- SELESNIK I. W., BARANIUK R. G., KINGSBURY N. C., 2005. The dual-tree complex wavelet transform. *IEEE Signal Processing Magazine*, vol. 22, no. 6, pp. 123-151.
- STITOU Y., LASMAR N.-E., BERTHOUMIEU Y., 2009. Copulas based multivariate gamma modeling for texture classification. *Proceedings of the 2009 IEEE International Conference on Acoustics, Speech and Signal Processing*, pp. 1045-1048.
- ST-ONGE B., CAVAYAS F., 1997. Automated forest structure mapping from high resolution imagery based on directional semivariogram estimates. *Remote Sensing of Environment*, vol.61, pp. 82-95.
- THYAGARAJAN K. S., NGUYEN T., PERSONS C., 1994. A maximum likelihood approach to texture classification using wavelet transform. *Proceedings of the 1994 IEEE International Conference on Image Processing*, vol. 2, pp. 640-644.
- TRIAS-SANZ R., 2006. Texture orientation and period estimator for discriminating between forests, orchards, vineyards, and tilled fields. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 44, no. 10, pp. 2755-2760.
- TUCERYAN M., JAIN A. K., 1998. Texture analysis. *The handbook of pattern recognition and computer vision*, vol. 2, pp. 207-248.
- UNSER M., 1995. Texture classification and segmentation using wavelet frames. *IEEE Transactions on Image Processing*, vol. 4, no. 11, pp. 1549-1560.
- VALERO S., SALEMBIER P., CHANUSSOT J., 2010. New hyperspectral data representation using binary partition tree. *Proceedings of the 2010 IEEE International Geoscience and Remote Sensing Symposium*, pp. 80-83.
- VAN COILLIE F. M. B., VERBEKE L. P. C., DE WULF R. R., 2008. Semi-automated forest stand delineation using wavelet-based segmentation of very high resolution optical imagery in Flanders, Belgium. In *Object-Based Image Analysis*, Springer Berlin Heidelberg, pp. 237-256.
- VAN DE WOUWER G., SCHEUNDERS P., VAN DYCK D., 1999. Statistical texture characterization from discrete wavelet representations. *IEEE Transactions on Image Processing*, vol. 8, no. 4, pp. 592-598.
- VAPNIK V., 1995. The nature of statistical learning theory. Springer-Verlag, New York.

- VASCONCELOS N., HO P., MORENO P., 2004. The Kullback-Leibler kernel as a framework for discriminant and localized representations for visual recognition. *Computer Vision-ECCV 2004*, pp. 430-441.
- VASILE G., OVARLEZ J.-P., PASCAL F., TISON C., 2010. Coherency matrix estimation of heterogeneous clutter in high-resolution polarimetric SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 48, no. 4, pp. 1809-1826.
- VASILE G., BESIC N., ANGHEL A., IOANA C., CHANUSSOT J., 2013. Sphericity of complex stochastic models in multivariate SAR images. *Proceedings of the 2013 IEEE International Geoscience and Remote Sensing Symposium*, pp. 2994-2997.
- VERDOOLAEGE G., DE BACKER S., SCHEUNDERS P., 2008. Multiscale colour texture retrieval using geodesic distance between multivariate generalized Gaussian models. *Proceedings of the 2008 IEEE International Conference on Image Processing*, pp. 169-172.
- VERDOOLAEGE G., SCHEUNDERS P., 2012. Geometry of multivariate generalized Gaussian models. *Journal of Mathematical Imaging and Vision*, vol. 43, no. 3, pp. 180-193.
- VISTEX. Vision Texture Database, MIT Media Laboratory's vision and modeling group.  
<http://vismod.media.mit.edu/vismod/imagery/VisionTexture>
- VOISIN A., KRYLOV V. A., MOSER G., SERPICO S. B., ZERUBIA J., 2013. Classification of very high resolution SAR images of urban areas using copulas and texture in a hierarchical Markov random field model. *IEEE Geoscience and Remote Sensing Letters*, vol. 10, no. 1, pp. 96-100.
- WARNER T. A., STEINMAUS K., 2005. Spatial classification of orchards and vineyards with high spatial resolution panchromatic imagery. *Photogrammetric Engineering and Remote Sensing*, vol. 71, no. 2, pp. 179-187.
- WASSENAAR T., ROBBEZ-MASSON J.-M., ANDRIEUX P., 2002. Vineyard identification and description of spatial crop structure by per-field frequency analysis. *International Journal of Remote Sensing*, vol. 23, no. 17, pp. 3311-3325.
- YAO K., 1973. A representation theorem and its applications to spherically-invariant processes. *IEEE Transactions on Information Theory*, vol. IT-9, no. 5, pp. 600-608.
- YU Q., GONG P., CLINTON N., BIGING G., KELLY M., SCHIROKAUER D., 2006. Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. *Photogrammetric Engineering and Remote Sensing*, vol. 72, no. 7, pp. 799-811.



# Liste des publications de l'auteur

## Articles de revues avec comité de lecture

- **REGNIERS O.**, BOMBRUN L., GUYON D., SAMALENS J.-C., GERMAIN C., 2014. Wavelet-based texture features for the classification of age classes in a maritime pine forest. *IEEE Geoscience and Remote Sensing Letters*, vol. 12, no. 3, pp. 621-625.
- **REGNIERS O.**, BOMBRUN L., GERMAIN C., 2014. Modélisation de texture basée sur les ondelettes pour la détection de parcelles viticoles à partir d'images Pléiades panchromatiques. *Revue Française de Photogrammétrie et de Télédétection*, vol. 208, pp. 117-122.

## Articles dans des actes de conférences internationales avec comité de lecture

- **REGNIERS O.**, BOMBRUN L., GUYON D., SAMALENS J.-C., TINEL C., GRENIER G., GERMAIN C., 2014. Wavelet based texture modeling for the classification of very high resolution maritime pine forest images. *Proceedings of the 2014 IEEE International Geoscience and Remote Sensing Symposium*, pp. 2027-203.
- **REGNIERS O.**, BOMBRUN L., LAFON V., DEHOUCK A., TINEL C., GERMAIN C., 2014. Wavelet based texture modeling for panchromatic very high resolution image classification: application to oyster racks detection. *Proceedings of the 2014 IEEE International Geoscience and Remote Sensing Symposium*, pp. 5148-5151.
- **REGNIERS O.**, DA COSTA J.-P., GRENIER G., GERMAIN C., BOMBRUN L., 2013. Texture based image retrieval and classification of very high resolution maritime pine forest images. *Proceedings of the 2013 IEEE International Geoscience and Remote Sensing Symposium*, pp. 4038-4041.
- **REGNIERS O.**, GOVIND A., GUYON D., WIGNERON J.-P., BARET F., 2012. A multiscale and multisensor approach of LAI retrieval in a maritime pine ecosystem," *Proceedings of the 2012 IEEE International Geoscience and Remote Sensing Symposium*, pp.1695-1698.

## Conférences internationales avec comité de lecture

- LAFON V., CLOS G., DUCROT D., DEHOUCK A., **REGNIERS O.**, Multi-temporal and multi-sensor classification applied to intertidal flat mapping. *IEEE International Geoscience and Remote Sensing Symposium*, Québec City, juillet 2014 (poster).

## Conférences nationales sans comité de lecture

- **REGNIERS O.**, BOMBRUN L., GERMAIN C., Utilisation d'outils de modélisation de texture pour la classification d'images Pléiades panchromatiques : application à la détection de parcelles viticoles. *Pléiades Days 2014*, Toulouse, avril 2014 (présentation orale).

- **REGNIERS O.**, BOMBRUN L., GUYON D., SAMALENS J.-C., GERMAIN C., Modélisation de texture par ondelettes pour la classification d'images THR panchromatiques : application à la différenciation de classes d'âge de forêt de pin maritime. *Pléiades Days 2014*, Toulouse, avril 2014 (poster).
- **REGNIERS O.**, BOMBRUN L., GERMAIN C., LAFON V., Utilisation d'outils de modélisation de texture pour la classification d'images Pléiades panchromatiques : application à la détection de parcelles ostréicoles dans le bassin d'Arcachon. *Pléiades Days 2014*, Toulouse, avril 2014 (poster).
- LAFON V., TERTRE N., CURTI C., SIMMONET B., **REGNIERS O.**, DEHOUCK A., BACHELET G., Cartographie des champs d'huîtres par télédétection très haute résolution spatiale – Application au Bassin d'Arcachon. *Colloque Carhamb'ar*, Ifremer Brest, mars 2013 (poster).



# Résumé

Le travail présenté dans cette thèse a pour objectif d'évaluer le potentiel de modèles probabilistes multivariés appliqués sur les sous-bandes d'une décomposition en ondelettes pour la classification d'images de télédétection optiques à très haute résolution spatiale. Trois thématiques principales ont été investiguées dans ce travail : la différenciation de classes d'âge de peuplements de pins maritimes, la détection de parcelles viticoles et la détection de parcs ostréicoles. Une contribution originale concerne la proposition d'une chaîne traitement pour une classification supervisée orientée objet se basant sur des mesures de similarité adaptées au contexte de modélisation probabiliste. Celle-ci implique la création d'une base de données de patches de texture pour l'apprentissage et l'utilisation d'une pré-segmentation de l'image à classifier. Les modèles probabilistes multivariés testés ont tout d'abord été évalués dans une procédure d'indexation d'images. Les modèles les plus performants identifiés par cette procédure ont été ensuite appliqués dans la chaîne de traitement proposée. Dans les trois thématiques explorées, les modèles multivariés ont révélé des capacités remarquables de représentation de la texture et ont permis d'obtenir une qualité de classification supérieure à celle obtenue par la méthode des matrices de co-occurrence. Ces résultats démontrent l'intérêt de la représentation multi-échelles et multi-orientations de la texture dans l'espace transformé en ondelettes et la pertinence de la modélisation multivariée des coefficients d'ondelettes issus de cette décomposition.

**Mots-Clés** analyse de texture, modélisation multivariée, transformée en ondelettes, très haute résolution spatiale, classification, satellites Pléiades, forêt, vigne, parcs ostréicoles

# Abstract

The prime objective of this thesis is to evaluate the potential of multivariate probabilistic models applied on wavelet subbands for the classification of very high resolution remote sensing optical data. Three main applications are investigated in this study: the differentiation of age classes of maritime pine forest stands, the detection of vineyards and the detection of oyster fields. One main contribution includes the proposal of an original supervised and object-oriented classification scheme based on similarity measurements adapted to the context of probabilistic modeling. This scheme involves the creation of a database of texture patches for the learning step and a pre-segmentation of the image to classify. The tested multivariate models were first evaluated in an image retrieval framework. The best models identified in this procedure were then applied in the proposed image processing scheme. In the three proposed thematic applications, multivariate models revealed remarkable abilities to represent the texture and reached higher classification accuracies than the method based on co-occurrence matrices. These results confirm the interest of the multi-scale and multi-orientation representation of textures through the wavelet transform, as well as the relevance of the multivariate modeling of wavelet coefficients.

**Keywords** texture analysis, multivariate modeling, wavelet transform, very high resolution, classification, Pléiades satellite, forest, vineyards, oyster fields